



**TAHMİN MODELLERİNDE VERİ
KAYMALARININ AÇIKLANABİLİR YAPAY
ZEKÂ ARAÇLARIYLA TESPİT EDİLMESİ**

Yüksek Lisans

Uğur DAR

Eskişehir 2024

**TAHMİN MODELLERİNDE VERİ KAYMALARININ AÇIKLANABİLİR
YAPAY ZEKÂ ARAÇLARIYLA TESPİT EDİLMESİ**

Uğur DAR

Yüksek Lisans Tezi

İstatistik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mustafa ÇAVUŞ

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Temmuz 2024

Bu tez çalışması BAP Komisyonu tarafından kabul edilen 22LÖT175 no.lu proje kapsamında ve TÜBİTAK 2210/C Yurt İçi Öncelikli Alanlar Yüksek Lisans Burs Programı 1649B022303919 no.lu proje kapsamında desteklenmiştir.

JÜRİ VE ENSTİTÜ ONAYI

Uğur DAR'ın TAHMİN MODELLERİNDE VERİ KAYMALARININ AÇIKLANABİLİR YAPAY ZEKÂ ARAÇLARIYLA TESPİT EDİLMESİ başlıklı çalışması 25/07/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek “Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği”nin ilgili maddeleri uyarınca, İstatistik Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye	: Dr. Öğr. Üyesi Mustafa ÇAVUŞ
Üye	: Doç. Dr. Emre ÇİMEN
Üye	: Doç. Dr. Eyüp ÇINAR

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

25/07/2024

DANIřMAN ONAYI

Daniřmanlıęını yrttęm Yksek Lisans ęrencisi Uęur DAR, TAHMİN MODELLERİNDE VERİ KAYMALARININ AÇIKLANABİLİR YAPAY ZEKÂ ARAÇLARIYLA TESPİT EDİLMESİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduęu tez tarafımca incelenmiř ve ęrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtır.

Tez Daniřmanı

Dr. ęr. yesi Mustafa AVUř

ÖZET

TAHMİN MODELLERİNDE VERİ KAYMALARININ AÇIKLANABİLİR YAPAY ZEKÂ ARAÇLARIYLA TESPİT EDİLMESİ

Uğur DAR

İstatistik Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Temmuz 2024

Danışman: Dr. Öğr. Üyesi Mustafa ÇAVUŞ

Kavram kayması, veri setlerinde zamanla meydana gelen ve tahmin modellerinin performansını olumsuz etkileyen değişikliklerdir. Bu tezde, kavram kaymasının tespitinde kullanılan klasik istatistiksel yöntemlerin bazı durumlarda yetersiz kaldığı ele alınmış ve bu eksiklikleri gidermek amacıyla Açıklanabilir Yapay Zeka (AYZ) yöntemlerinden biri olan Kısmi Bağımlılık Profili (PDP) baz alınarak yeni bir yöntem geliştirilmiştir: Profil Kayması Tespiti (PDD – *Profile Drift Detection*). Bu yeni yöntem, PDP eğrileri arasındaki değişiklikleri profillerin öklidyen uzaklıkları, türevleri arasındaki öklidyen uzaklık ve Profile Disparity Index (PDI) metrikleri ile değerlendirir.

Çalışmada, literatürde bu konuda sıkça kullanılan sentetik ve gerçek hayat veri setleri kullanılarak, farklı yığın (*batch*) sayılarında veriler bölüntülenerek istatistiksel testler ve PDD yöntemi karşılaştırılmıştır. PDD, genellikle daha az sayıda kavram kayması tespit etmesine rağmen, model performansı bakımından istatistiksel testlerle benzer veya daha iyi sonuçlar göstermiş ve yığın sayısı değiştiğinde de tutarlı sonuçlar vermiştir. PDD, model ile veri arasındaki ilişkinin daha detaylı incelenmesine olanak tanır. Önerilen yöntemin performansı, farklı yığın büyüklükleri için sentetik ve gerçek hayat verileri üzerinde yapılan deneysel çalışmalarla araştırılmıştır. Elde edilen bulgulara göre yöntemin kullanılabilirliği tartışılmıştır.

Anahtar Sözcükler: Kavram kayması, Açıklanabilir yapay zeka, Kısmi bağımlılık profili, Profil kayması tespiti, Makine öğrenmesi.

ABSTRACT

DETECTING DATA DRIFTS IN PREDICTIVE MODELS BY EXPLAINABLE ARTIFICIAL INTELLIGENCE TOOLS

Uğur DAR

Department of Statistics

Eskişehir Technical University, Institute of Graduate Programs, July 2024

Supervisor: Asst. Prof. Dr. Mustafa ÇAVUŞ

Concept drift refers to changes in data sets over time that negatively impact the performance of predictive models. This thesis addresses the limitations of traditional statistical methods used to detect concept drift and proposes a new method based on Partial Dependence Profile (PDP), an eXplainable Artificial Intelligence (XAI) technique: Profile Drift Detection (PDD). This new method evaluates changes in PDP curves using metrics such as Euclidean distances between profiles, Euclidean distances between their derivatives, and the Profile Disparity Index (PDI).

The study compares traditional statistical tests and the Profile Drift Detection (PDD) method using synthetic and real-world data sets commonly used in the literature. The data sets are divided into different batch sizes for analysis. PDD generally detects fewer instances of concept drift while achieving similar or better model performance compared to statistical tests, and it provides consistent results when batch sizes vary. Additionally, PDD enables a more detailed examination of the relationship between the model and the data. The performance of the proposed method is investigated through experimental studies conducted on synthetic and real-world data for different batch sizes. The usability of the method is discussed based on the findings.

Keywords: Concept drift, Explainable artificial intelligence, Partial dependence profile, Profile drift detection, Machine learning.

TEŞEKKÜR

Öncelikle lisans, yüksek lisans ve tezimin her aşamasında bana yön gösteren, her konuda büyük destek sağlayan ve bana ilham veren değerli danışmanım Dr. Öğr. Üyesi Mustafa ÇAVUŞ'a en içten teşekkürlerimi sunarım. Kendisinin teşvik edici tutumu, takibi ve rehberliği bu çalışmanın ortaya çıkmasında büyük bir rol oynamıştır. Kendisinden öğrendiğim değerli bilgilerin ve kazanımların, bundan sonraki akademik ve profesyonel hayatımda da bana yol göstereceğine inanıyorum.

Şu an aramızda olmayan ancak eğitim hayatım boyunca beni öğrenmeye teşvik eden, her zaman motivasyon kaynağım olan babaannem Aynur DAR'a, beni sabır ve sevgiyle büyüten her zaman desteklerini hissettiğim anneme ve babama sonsuz teşekkürlerimi sunarım.

Uğur DAR

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Uğur DAR

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
TABLolar DİZİNİ.....	X
ŞEKİLLER DİZİNİ.....	XI
SİMGELER VE KISALTMALAR DİZİNİ.....	XIV
1. GİRİŞ	1
2. KAVRAM KAYMASI.....	4
2.1. Gerçek Kavram Kayması	5
2.2. Sanal Kavram Kayması.....	5
2.3. Kavram Kayması Türleri.....	6
2.4. Kavram Kayması Tespit Yöntemleri	7
2.4.1. Kavram kayması tespit yöntemi (DDM- <i>drift detection method</i>)	8
2.4.2. Erken kavram kayması tespit yöntemi (EDDM - <i>early drift detection method</i>).....	9
2.4.3. Hoeffding eşitsizliğine dayalı kavram kayması yöntemi (HDDM – <i>Hoeffding's drift detection method</i>).....	10
2.4.3.1. HDDM-A (<i>average</i>)	10
2.4.3.2. HDDM-W (<i>weighted</i>).....	11
2.4.4. Uyarlanabilir pencere yöntemi (ADWIN – <i>adaptive windowing</i>)	

2.4.5. Kolmogorov-Smirnov pencereleme yöntemi (KSWIN – <i>Kolmogorov-Smirnov windowing</i>)	13
2.4.6. Kümülatif toplamlar yöntemi (CUSUM – <i>cumulative sums</i>)	14
2.4.7. Page Hinkley testi (PH)	14
3. MATERYAL VE YÖNTEM.....	16
3.1. Açıklanabilir Yapay Zeka (XAI – eXplainable Artificial Intelligence)	16
3.2. Ceteris-Paribus Profilleri (CP) ve Kısmi Bağımlılık Profilleri (PDP- Partial Dependence Profiles)	17
3.3. Profil Farklılıklarının Ölçülmesi	19
3.4. Metriklerin Hesaplanması.....	20
3.5. Profil Kayması Tespiti (PDD – Profile Drift Detection)	21
3.6. datadriftR Paketi.....	23
4. UYGULAMALAR	25
4.1. SEA Veri Seti.....	25
4.2. Hyperplane Veri Seti.....	33
4.3. NOAA (Weather) Veri Seti	42
4.4. Ozone Veri Seti.....	47
4.5. Elec2 Veri Seti	51
4.6. Friedman Veri Seti (Regresyon)	58
5. SONUÇ	65
KAYNAKÇA.....	69
EKLER	
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 4.1. SEA veri seti için deney sonuçları	26
Tablo 4.2. Hyperplane veri seti için deney sonuçları	34
Tablo 4.3. NOAA veri seti için deney sonuçları	42
Tablo 4.4. Ozone veri seti için deney sonuçları	47
Tablo 4.5. Elec2 veri seti için deney sonuçları	52
Tablo 4.6. Friedman veri seti için deney sonuçları	59



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Veri kayması taksonomisi	4
Şekil 2.2. Gerçek ve sanal kavram kayması	6
Şekil 2.3. Kavram kayması türleri	7
Şekil 3.1. Örnek PDP	18
Şekil 3.2. PDD algoritması	22
Şekil 4.1. SEA veri seti için yığın-3 üzerinde PDD'nin kavram kayması tespiti.....	28
Şekil 4.2. SEA veri seti için yığın-5 üzerinde PDD'nin kavram kayması tespiti.....	29
Şekil 4.3. SEA veri seti için yığın-10 üzerinde PDD'nin kavram kayması tespiti.....	29
Şekil 4.4. SEA veri seti için yığın-15 üzerinde PDD'nin kavram kayması tespiti.....	30
Şekil 4.5. SEA veri seti için yığın-20 üzerinde PDD'nin kavram kayması tespiti.....	31
Şekil 4.6. SEA veri seti için yığın-25 üzerinde PDD'nin kavram kayması tespiti.....	32
Şekil 4.7. SEA veri seti için yığın-30 üzerinde PDD'nin kavram kayması tespiti.....	32
Şekil 4.8. Hyperplane veri seti için yığın-3 üzerinde PDD2'nin kavram kayması tespiti.....	35
Şekil 4.9. Hyperplane veri seti için yığın-5 üzerinde PDD2'nin kavram kayması tespiti.....	36
Şekil 4.10. Hyperplane veri seti için yığın-10 üzerinde PDD2'nin kavram kayması tespiti.....	37
Şekil 4.11. Hyperplane veri seti için yığın-15 üzerinde PDD2'nin kavram kayması tespiti.....	38
Şekil 4.12. Hyperplane veri seti için yığın-20 üzerinde PDD2'nin kavram kayması tespiti.....	39
Şekil 4.13. Hyperplane veri seti için yığın-25 üzerinde PDD2'nin kavram kayması tespiti.....	40
Şekil 4.14. Hyperplane veri seti için yığın-30 üzerinde PDD2'nin kavram kayması tespiti.....	41
Şekil 4.15. NOAA veri seti için yığın-3 üzerinde PDD'nin kavram kayması tespiti.....	44
Şekil 4.16. NOAA veri seti için yığın-5 üzerinde PDD'nin kavram kayması tespiti.....	44
Şekil 4.17. NOAA veri seti için yığın-10 üzerinde PDD'nin kavram kayması tespiti.....	45

Şekil 4.18. NOAA veri seti için yığın-15 üzerinde PDD'nin kavram kayması tespiti.....	45
Şekil 4.19. NOAA veri seti için yığın-25 üzerinde PDD'nin kavram kayması tespiti.....	46
Şekil 4.20. NOAA veri seti için yığın-30 üzerinde PDD'nin kavram kayması tespiti.....	46
Şekil 4.21. Ozone veri seti için yığın-3 üzerinde PDD'nin kavram kayması tespiti.....	49
Şekil 4.22. Ozone veri seti için yığın-10 üzerinde PDD'nin kavram kayması tespiti.....	49
Şekil 4.23. Ozone veri seti için yığın-15 üzerinde PDD'nin kavram kayması tespiti.....	50
Şekil 4.24. Ozone veri seti için yığın-25 üzerinde PDD'nin kavram kayması tespiti.....	50
Şekil 4.25. Ozone veri seti için yığın-30 üzerinde PDD'nin kavram kayması tespiti.....	51
Şekil 4.26. Elec2 veri seti için yığın-5 üzerinde PDD2'nin kavram kayması tespiti	53
Şekil 4.27. Elec2 veri seti için yığın-10 üzerinde PDD2'nin kavram kayması tespiti.....	54
Şekil 4.28. Elec2 veri seti için yığın-15 üzerinde PDD2'nin kavram kayması tespiti.....	55
Şekil 4.29. Elec2 veri seti için yığın-20 üzerinde PDD2'nin kavram kayması tespiti.....	56
Şekil 4.30. Elec2 veri seti için yığın-25 üzerinde PDD2'nin kavram kayması tespiti.....	57
Şekil 4.31. Elec2 veri seti için yığın-30 üzerinde PDD2'nin kavram kayması tespiti.....	58
Şekil 4.32. Friedman veri seti için yığın-3 üzerinde PDD2'nin kavram kayması tespiti.....	60
Şekil 4.33. Friedman veri seti için yığın-5 üzerinde PDD2'nin kavram kayması tespiti.....	61
Şekil 4.34. Friedman veri seti için yığın-10 üzerinde PDD2'nin kavram kayması tespiti.....	61

Şekil 4.35. Friedman veri seti için yığın-15 üzerinde PDD2'nin kavram kayması	
tespiti.....	62
Şekil 4.36. Friedman veri seti için yığın—20 üzerinde PDD2'nin kavram kayması	
tespiti.....	62
Şekil 4.37. Friedman veri seti için yığın-25 üzerinde PDD2'nin kavram kayması	
tespiti.....	63
Şekil 4.38. Friedman veri seti için yığın-30 üzerinde PDD2'nin kavram kayması	
tespiti.....	64



SİMGELER VE KISALTMALAR DİZİNİ

α	: Alpha
β	: Beta
λ	: Lambda
DDM	: Drift Detection Method
EDDM	: Early Drift Detection Method
ADWIN	: Adaptive Windowing
KSWIN	: Kolmogorov-Smirnov Windowing
HDDM-A	: Hoeffding's Drift Detection Method - Average
HDDM-W	: Hoeffding's Drift Detection Method - Weighted
CUSUM	: Cumulative Sum
PH	: Page Hinkley
XAI	: eXplainable Artificial Intelligence
AYZ	: Açıklanabilir Yapay Zekâ
PDP	: Partial Dependence Profile
CP	: Ceteris-Paribus
PDD	: Profile Drift Detection
PDI	: Profile Disparity Index
SHAP	: SHapley Additive exPlanations
$P_{t_k}(X, y)$	: k. anda yanıt değişkeni ve bağımsız değişkenlerin ortak (joint) olasılık fonksiyonu.
$P_{t_k}(y X)$	: k. anda X bilindiğinde y'nin koşullu olasılık dağımı.
$P_{t_k}(y)$	: k. anda y'nin (yanıt değişkeni) olasılık dağılımı.
$P_{t_k}(x)$	: k. anda x bağımsız değişkeninin olasılık dağımı.
$\hat{y}_i$	: i. gözlemin tahmin değeri.
p_i	: i. gözlemdeki hata oranı.
s_i	: i. gözlemdeki hata oranının varyansı.
d_{L^2}	: Profiller arasındaki L2 farkı.
$d_{L^2, der}$	: Profillerin türevlerinin arasındaki L2 farkı.
g_{f_i}	: i. PDP

1. GİRİŞ

Tahmin modellerinde durağan ve yansız dağılım varsayımı, eğitim ve test kümelerinde yer alan gözlemlerin bağımsız ve aynı dağılımlı olmasıdır (Cieslak & Chawla, 2009). Ancak bu varsayım pratikte sıklıkla gerçekleşmez ve tahmin modellerin performansında önemli düşüslere neden olabilir (Alaiz-Rodriguez & Japkowicz, 2008). Bu varsayımın sağlanmaması durumu, literatürde veri kayması olarak adlandırılır (Moreno-Torres vd., 2012). Veri kaymasının tespiti için çok sayıda yöntem kullanılmaktadır. Bu yöntemler, İstatistiksel, Ardışık analize dayalı, Pencere tabanlı olmak üzere üç gruba ayrılırlar (Masciopinto, 2018). Veri kayması türleri ise üç gruba ayrılır: (1) Kovaryant kayması, (2) Yanıt değişkeni kayması, (3) Kavram kayması (Moreno-Torres vd., 2012). Veri kayması türlerinden, bağımsız değişkenler ve yanıt değişkeni arasındaki ilişkinin değişimi olarak gözlemlenen kavram kaymasının tespiti için literatürde bulunan yöntemlerin yetersiz kaldığı durumlar olmaktadır (Demsar ve Bosnic, 2018; Duckworth vd., 2021; Rahmani vd., 2022). Bu durumlardan en zorlarından biri, kullanılan tespit yöntemlerinin performans ve dağılım ölçülerine bağlı olması nedeniyle, bu iki metrik değişmediği durumlarda ortaya çıkan kavram kayması durumudur. Bu durumda literatürde bulunan yöntemler yeterince güvenilir sonuçlar vermeyebilir.

Literatürde kavram kaymasını tespit etmek için kullanılan yöntemlerinin yeterli performans gösteremediği bu duruma çözüm olarak bazı yöntemler önerilmiştir:

Demsar ve Bosnic (2018) mevcut veri kayması tespit yöntemlerinin sadece performans ve dağılım ölçülerine bağlı olduğunu ve bu durumun modelde meydana gelen değişimlerin arkasında yatan nedeni anlamak için yeterli olmadığına vurgu yapmıştır. Lokal açıklanabilir model açıklayıcı (Štrumbelj vd., 2009) aracını kullanarak alternatif bir yöntem geliştirmiş ve mevcut yöntemlere göre daha iyi bir tespit performansı gösterdiğini karşılaştırma çalışmalarıyla ortaya çıkarmıştır. Duckworth vd. (2021) normalleştirilmiş SHAP yöntemini kullanarak COVID-19 sonrası acil servis yatış süresi tahmin modellerindeki veri kaymalarını tespit etmiştir. Bu yolu izlemesinin nedeninin, klasik yöntemlerin modelin bilgi kullanımındaki değişimi yansıtamaması olduğu belirtmiştir. Mougan ve Nielsen (2023) istatistiksel testlerin sadece verinin dağılımı üzerinden hesaplama yaptığı ve yanlış alarmlar verdiğine vurgu yapmıştır, çalışmalarında parametrik olmayan yeniden örneklemeli (*bootstrap*) bersizlik tahmini (*uncertainty estimation*) ve SHAP değerlerini kullanarak regresyon problemlerinde açıklanabilir bir

kavram kayması yöntemi geliřtirmiřtir. Mattos vd. (2006) kavram kayması tespit yöntemlerinin kaymanın nedeni ve açıklanabilirliđi üzerine literatürde çok fazla çalışma olmamasına değinmiřtir. Kavram kaymasını tespit etmek ve açıklamak için karar ağacı modeline dayalı, karar ağacının bölüntü yaptıđı bölgelerdeki değışiklikler üzerinden tespit yapan ve görselleřtiren bir yöntem geliřtirmiřtir, ancak kaymayı tespit etmek için sürekli model eğitmenin maliyeti ve model tarafından seçilen kısıtlı sayıda değışkenin takibinin mümkün olması gibi yöntemin kısıtlılıklarını tartıřmıřlardır. Ayrıca ağaç tabanlı olmayan modeller kullanıldığında yöntem modelin karar sürecinden farklı iliřkileri değerdendirebilir, bu nedenle daha çok model-spesifik (ağaç tabanlı yöntemler) bir yöntem olarak değerdendirilebilir. Muschalik vd. (2022) permütasyonel değışken önemliliđi değerdelerini kullanarak kavram kaymasını tespit etmeye yarayan bir yaklařım geliřtirmiřtir. Benzer řekilde Fumagalli vd. (2023) artımlı modellerde kullanılmak üzere ve artımlı permütasyonel değışken önemliliđi yöntemini geliřtirmiřtir. Ancak geliřtirdikleri yaklařımın etkin bir řekilde uygulanabilmesi için karmařıklık, etkinlik, duyarlılık ve açıklanabilirlik gibi noktalardaki eksikliklerin giderilmesi gerektiđinin altını çizmiřlerdir. Rahmani vd. (2022) çalışmalarında en sık kullanılan açıklanabilir yapay zeka araçlarından SHAP yöntemini kullanarak modelde gözlenen veri kaymalarını değışken önemlilikleri özelinde arařtırmıřlardır. Karşılařtıkları en önemli zorluk ise kovaryant ve kavram kaymasının birbirinden ayırlamamasıdır. Bu zorluđun ortaya çıkıřındaki en önemli nedenin uygun açıklanabilir yapay zekâ aracının kullanılmamasıdır. Çünkü SHAP yöntemi değışken önemlilikleri hakkında yeterli bilgi verebilirken, açıklayıcı ve yanıt değışkeni arasındaki iliřkinin tespitinde yeterince başarılı olmamalarıdır.

Görüldüđü gibi literatürde açıklanabilir yapay zekâ araçlarını kullanarak, veri kayması tespit yöntemleri geliřtirilen çok az sayıda çalışma bulunmaktadır. Bulunan çalışmaların da bazı kavram kayması durumlarında yeterince başarılı olmaması ya da hesaplama maliyeti yüksek olan permütasyonel değışken önemliliđi veya SHAP yöntemine dayalı olduđu görülmektedir. Bu nedenlerden dolayı yanıt değışkeni ve bağımsız değışkenler arasındaki iliřki değışimini tespit etmek için kullanıřlı değildir (Biecek ve Burzykowski, 2021).

Literatürde Kısmi Bağımlılık Profillerini (PDP - *Partial Dependence Profile*) kullanarak kavram kayması tespitine yönelik Muschalik vd. (2023) tarafından iPDP (*Incremental Partial Dependence Profile*) önerilmiřtir. iPDP çevrim-içi öğrenme

ortamlarında artırımı modeller kullanıldığında PDP eğrisinin güncellenmesini sağlar. Bu güncelleme sırasında belirlenen bir parametre ile yeni gelen gözlemler ile önceki gözlemler ağırlıklandırılarak yeni bir PDP elde edilir. Ancak iPDP yöntemi kavram kayması tespitine yönelik herhangi bir metrik önermemektedir. Diğer yaklaşımlara benzer şekilde ADWIN yöntemi kullanılarak, doğruluk metriği üzerinden kavram kayması tespit etmeye çalışılmıştır.

PDP'ler yanıt değişkeni ile bağımsız değişkenler arasındaki ilişkiyi incelediği için farklı amaçlarla kullanılabilirler. Literatürde PDP, Moosbauer vd. (2021) tarafından hiper-parametre optimizasyonu, Inglis vd. (2022) tarafından ise değişken önemliliğinin belirlenmesi ve değişkenler arasındaki etkileşimin belirlenmesi gibi konularda da kullanılmıştır.

Bu çalışmada PDP'ye dayalı, kavram kayması problemine yönelik açıklanabilir bir çözüm önerisi geliştirilmesi amaçlanmaktadır. Kavram kayması tespiti için daha uygun olduğunu düşündüğümüz bu araçların kullanımına dayalı bir yöntem geliştirilmenin daha önce denenmemiş bir çözüm yolu olması bu çalışmanın özgün değerini oluşturmaktadır.

Bu tez çalışmasında;

- 2. Bölüm'de kavram kayması, kavram kaymasının türleri, kavram kayması tespit yöntemleri ele alınmıştır.
- 3. Bölüm'de açıklanabilirlik, Kısmi Bağımlılık Profili, profiller arasındaki farkın hesaplanması, geliştirilen Profil Kayması Tespiti yöntemi ve R paketi açıklanmıştır.
- 4. Bölüm'de 3 sentetik ve 3 gerçek hayat verisi üzerinde istatistiksel kavram kayması tespit yöntemleri ve geliştirilen yöntem farklı yığın (batch) sayıları için kıyaslanmıştır. Bu veri setlerinden 5'i ikili sınıflandırma, 1'i ise regresyon problemidir.
- 5. Bölüm'de araştırma bulguları, geliştirilen yöntemin avantaj ve dezavantajları tartışılmıştır.

2. KAVRAM KAYMASI


Kavram kayması modelin performansını genel olarak olumsuz bir şekilde etkiler ve günümüzde canlı sistemler üzerinde modeller üzerinden anlık kararlar verilmektedir. Bu tip kararların yanlış verilmesi büyük maliyetler oluşmasına neden olabilmektedir.

Eğitilen modelin zaman içerisinde iyi sonuçlar vermemesinin nedeni, t_0 anında bu ilişkiyi temsil edebiliyorken verideki değişkenlerin dağılımlarının değişmesi ya da bağımsız değişkenler ile yanıt değişkeni arasındaki ilişkinin değişmesi sonucunda modelin temsil yeteneğini zaman içerisinde kaybetmesinden kaynaklanabilir. Bu iki durumdan ilki literatürde sanal kavram kayması, diğeri ise gerçek kavram kayması olarak ele alınmıştır.

Model eğitiminde kullanılan bağımsız değişkenler, $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ i . bağımsız değişken, y yanıt değişkeni, $P_{t_0}(X, y)$ modelin ilk eğitildiği andaki ortak olasılık fonksiyonu, $P_{t_i}(X, y)$ modelin eğitildikten sonraki herhangi bir andaki ortak (*joint*) olasılık fonksiyonu olmak üzere kavram kayması;

$$\exists X : P_{t_0}(X, y) \neq P_{t_i}(X, y) , i > 0 \quad (2.1)$$

şeklinde tanımlanır.



Şekil 2.1. Veri kayması taksonomisi

Şekil 2.1.'de veri kayması taksonomisi verilmiştir. Literatürde yer yer veri kayması, kavram kayması olarak da isimlendirilmiştir ve iki başlık altında incelenmiştir (Celik vd., 2022).

2.1. Gerçek Kavram Kayması

Gerçek kavram kayması, makine öğrenmesi modelinin t_0 anında yanıt değişkeni ve bağımsız arasındaki ilişkiyi iyi temsil etmesine rağmen t_i anında bu ilişkinin değişmesini ifade eden bir olgudur. Bu değişiklikler, veri özelliklerinin zamanla değişmesi veya veri akışındaki dinamiklerin değişmesi gibi nedenlerden kaynaklanabilir (Celik vd., 2022).

$$\exists X : P_{t_0}(y | X) \neq P_{t_i}(y | X) , i > 0 \quad (2.2)$$


Bu denklemden $P_{t_0}(y | X)$, t_0 anında X değişkenlerine bağlı olarak y yanıt değişkeninin koşullu olasılık dağılımını ifade eder. Yani verilen X değerleri altında, y yanıt değişkeninin hangi değerler alabileceğini ve bu değerlerin olasılık dağılımını verir. Denklemin sağ tarafında ise aynı durum t_i anındaki dağılımı temsil eder. Bu iki dağılımın eşit olmaması gerçek kavram kayması olarak adlandırılır.

2.2. Sanal Kavram Kayması

Sanal kavram kayması, t_0 anında eğitilen modeldeki X ve y arasındaki ilişkinin t_i anında değişmediği ancak X ya da y değişkenlerinin dağılımında değişiklik olduğu durumu ifade eder. Bu tür bir kavram kayması, modelin eğitim sürecinde öğrendiği ilişkinin aynı kaldığı, fakat modelin karşılaştığı veri dağılımının zaman içinde değiştiği anlamına gelir. Sanal kavram kayması ilişkinin değişmediği şu durumlarda ortaya çıkabilir, $i > 0$ olmak üzere;

$$P_{t_0}(y) \neq P_{t_i}(y) , i > 0 \quad (2.3)$$

$$P_{t_0}(x) \neq P_{t_i}(yx) , i > 0 \quad (2.4)$$




Şekil 2.2. Gerçek ve sanal kavram kayması

Sanal ve gerçek kavram kayması, veri akışındaki değişikliklerin hem bağımsız değişkenlerin dağılımında hem de bağımsız değişkenlerle yanıt değişkeni arasındaki ilişkide değişiklikler olması durumunda birlikte ortaya çıkabilir. Bu durum, modelin öğrenme yeteneğini önemli ölçüde etkileyebilir ve modelin mevcut veri akışına uygun hale getirilmesi için yeniden eğitilmesini gerektirebilir (Bkz. Şekil 2.2.). Böylece, modelin güncel veri koşullarına uyum sağlayarak doğru ve güvenilir tahminlerde bulunması sağlanabilir. Modelin performansını sürdürülebilir kılmak için düzenli olarak veri dağılımlarındaki değişikliklerin izlenmesi ve gerektiğinde modelin yeniden eğitilmesi büyük önem taşır.

2.3. Kavram Kayması Türleri

Kavram kayması, farklı tiplerde ortaya çıkabilmektedir literatürde genel olarak bu ayrım kademeli kavram kayması (*gradual drift*) ve ani kavram kayması (*sudden drift*) olarak sınıflandırılmıştır (Webb vd., 2016). Kademeli kavram kayması, verinin dağılımının zamanla yavaşça değiştiği bir kavram kayması türüdür. Bu durum modelin zamanla performansının azalmasına neden olabilir ve modelin yeniden eğitilmesi ya da güncellenmesi gerekebilir. Kademeli kavram kaymasının aksine verideki ani değişikliklerin olması ise literatürde ani kavram kayması olarak tanımlanmıştır. Ani kavram kaymasında yanıt değişkeni ve bağımsız değişkenler arasındaki ilişki aniden değişir ve böyle bir durumda model performansı aniden düşebilir ve model yanlış kararlar verebilir.



Şekil 2.3. Kavram kayması türleri

Literatürde kavram kayması farklı alt kategorilere ayrılarak da incelenmiştir (Friedrich vd., 2023). Ani kayma (*sudden drift*) verideki değişikliğin kalıcı olmasını ifade ederken yinelenen kayma (*recurring drift*) meydana gelen ani değişikliğin bir süre sonra tekrar eski haline gelmesini ifade etmektedir. Kademeli kayma (*gradual drift*) ise verideki gözlemlerin zamanla sapmalar göstererek, bu sapmaların yavaşça verinin yeni karakteristiğini oluşturmasını ifade etmektedir. Kademeli kaymaya benzer bir şekilde ancak sapmanın daha az olduğu ve zamanla verinin dağılımının değişmesi ise artımlı kayma (*incremental drift*) olarak ifade edilmektedir (Bkz. Şekil 2.3.).

2.4. Kavram Kayması Tespit Yöntemleri

Literatürde kavram kaymasını tespit etmek üzere farklı araçlar bulunmaktadır. Hepsinin kendine has avantaj ve dezavantajları mevcuttur. Bu testler farklı noktalarda ve sayılarda kavram kayması tespit edebilir. Bu tez çalışmasında kavram kayması tespitinde sıkça kullanılan istatistiksel yöntemler ele alınmıştır.

Veri kayması tespiti için kullanılan yöntemler literatürde genel olarak iki kategoride ele alınmaktadır. Bunlar, makine öğrenmesi modeli üzerinden yaklaşım ve istatistiksel testlerdir. Model üzerinden yaklaşımlar, doğruluk (*accuracy*), hata kareler ortalaması (*mean square error*), F1 skoru gibi model performansını ölçmek için kullanılan metrikleri temel alır. Genelde bu metriklerdeki değişim belirlenen bir eşik değerin üstünde ya da altında olması veri kaymasına işaret etmektedir.

Veri kaymasının tespitinde en sık kullanılan yöntemler istatistiksel testlerdir. İstatistiksel testlerin kullanılmasının en önemli nedenlerinden birisi bu testlerin hızlı bir şekilde çalışıyor olmasıdır. Bu testler genel olarak değişkenlerin dağılımını inceler ve bu dağılımlarda istatistiksel olarak anlamlı bir fark olduğunda veri kaymasına işaret eder.

İstatistiksel tespit yöntemleri de kendi içerisinde üç gruba ayrılır bunlar:

Ardışık Analize Dayalı Yöntemler (*Sequential Analysis based Methods*): Bu yöntemler, öngörü sonuçlarını elde edildikçe sıralı olarak değerlendirir ve önceden tanımlanmış bir eşik karşılandığında sapmalar için alarm verir. Kümülatif Toplamlar (Cumulative Sums - CUSUM), Geometrik Hareketli Ortalama Page Hinkley (*PH*) bu tip yöntemlere örnek olarak verilebilir.

İstatistiksel Tabanlı Yöntemler (*Statistical-based Methods*): Bu yöntemler, verinin istatistiksel karakteristiklerini araştırır. Genelde bu karakteristik özellikler ortalama ve standart sapmadır. Drift Tespit Metodu (*Drift Detection Method - DDM*), Erken Drift Tespit Metodu (*Early Drift Detection Method - EDDM*) ve Üstel Ağırlıklı Hareketli Ortalama (*Exponentially Weighted Moving Average - EWMA*) bu tip yöntemlere örnek olarak verilebilir.

Pencere Tabanlı Yöntemler (*Windows-based Methods*): Genellikle sabit bir referans penceresini kullanarak geçmiş dağılımları ve en son dağılımları özetleyen bir kayan pencere kullanılır. Bu pencerelerin dağılımları arasında önemli bir fark olması, veri kaymasının meydana geldiğini öne sürer. Uyarlanabilir Pencereleme (*Adaptive Windowing - ADWIN*), Hoeffding Drift Tespit Yöntemleri (*Hoeffding Drift Detection Methods – HDDM-A testi ve HDDM-W testi*) ve KSWIN (*Kolmogorov-Smirnov Windowing*) dedektörleri bu tip yöntemlere örnek olarak verilebilir.

2.4.1. Kavram kayması tespit yöntemi (DDM- *drift detection method*)

DDM, ikili sınıflandırma problemlerinde yanıt değişkenindeki (sınıf etiketi) değişiklikleri tespit etmek için kullanılan bir yöntemdir (Gama vd., 2004). Bu yöntem, veri akışının sürekli olduğu durumlarda uygulanır ve her yeni örnek geldiğinde modelin performansını değerlendirmek için kullanılır. Yeni gelen gözlemlerin (x_i, y_i) şeklinde gerçek değerlerle geldiği varsayılır. Model gelen gözlemler için $\hat{y}_i$ değerini Doğru ya da Yanlış olarak tahmin eder. Tahmin değerlerinin Doğru ya da Yanlış olması Bernouilli

dağılımıyla modellenenebilir. n adet gözlem geldiğinde ise bu dağılım Binom dağılımı ile modellenir. i örnek sayısı olmak üzere;

Hata Oranı (p_i): i . örnekteki modelin yaptığı hataların oranıdır. Belirli bir örnek kümesi üzerinde hesaplanır ve yanlış sınıflandırılan örneklerin toplam örnek sayısına oranıdır.

Standart Sapma (s_i): i . örnekteki hata oranının varyansını ölçen bir değerdir ve $s_i = \sqrt{p_i(1 - p_i)/i}$ şeklinde hesaplanır.

Hata oranı (p_i), Bernoulli denemelerinden türetilen bir rastgele değişkendir ve binom dağılımı ile temsil edilir. Yeterince büyük örnek boyutları için, binom dağılımı, aynı ortalama ve varyansa sahip normal dağılıma yakınsar. p_i 'nin $1 - \alpha/2$ güven aralığı $p_i \pm s_i$ şeklinde hesaplanır.

DDM hata oranındaki artışları izler. ($p_i + s_i$) belli bir eşik değeri geçerse kavram kaymasına işaret eder. %95 güven aralığı için $p_i + s_i \geq p_{min} + 2 * s_{min}$ şeklinde uyarı seviyesi olarak, %99 güven aralığı için $p_i + s_i \geq p_{min} + 3 * s_{min}$ kayma seviyesi olarak önerilmiştir. DDM modelden bağımsız kolay uygulanabilir bir algoritmadır. Sadece yanıt değişkeni üzerinden kavram kaymasını tespit etmeye çalışır yanıt değişkeni üzerinden bir kavram kayması tespit etmeye çalışan bir yöntem olduğundan, bağımsız değişkenlerde oluşan sanal kavram kaymasını tespit etmek için kullanılamaz.

2.4.2. Erken kavram kayması tespit yöntemi (EDDM - *early drift detection method*)

EDDM algoritması, DDM algoritmasına benzer bir yapı içerir. Güven aralıklarını kullanarak ikili sınıflandırma problemlerinde kavram kaymasını tespit etmek için geliştirilmiş bir yöntemdir (Baena-Garcia vd., 2006). Temel fark, DDM'de gelen her bir (x_i, y_i) gözlem için yapılan tahminin hata oranı hesaplanırken, EDDM algoritmasında ise bu hataların arasındaki mesafe hesaplanır. İki hata arasındaki ortalama uzaklık p'_i ve bu uzaklığın standart sapması s'_i hesaplanır ve kaydedilir. Bu değerler, $p'_i + 2 * s'_i$ maksimuma ulaştığında (p'_{maks} ve s'_{maks}) saklanır. Bu maksimum değer, modelin veri setindeki mevcut kavramları en iyi temsil ettiği anı gösterir. EDDM'de de DDM'deki gibi uyarı seviyesi ve kayma seviyesi için iki farklı eşik değeri belirlenmiştir.

$(p'_i + 2 * s'_i)/(p'_{maks} + 2 * s'_{maks}) < \alpha$ uyarı seviyesi olarak belirlenmiştir. Benzer biçimde $(p'_i + 2 * s'_i)/(p'_{maks} + 2 * s'_{maks}) < \beta$ ise kavram kayması seviyesi için belirlenmiştir. Kavram kayması tespit edildikten sonra modelin yeni kavrama uygun şekilde tekrar eğitildiği varsayılır ve p'_{maks} ve s'_{maks} değerleri sıfırlanır. Yapılan deneylerde α için 0.95 ve β için 0.90 değerleri önerilmiştir.

EDDM, yavaş yavaş gerçekleşen kavram kaymalarını daha iyi tespit etmek için tasarlanmış olup, ani değişimlere karşı da yüksek performans gösterir. EDDM, DDM'e benzer şekilde yanıt değişkeni üzerinden bir kavram kayması tespit etmeye çalışan bir yöntem olduğundan, bağımsız değişkenlerde oluşan sanal kavram kaymasını tespit etmek için kullanılamaz.

2.4.3. Hoeffding eşitsizliğine dayalı kavram kayması yöntemi (HDDM – Hoeffding's drift detection method)

Frias-Blanco vd. (2014) tarafından geliştirilen HDDM metodu ortalama ve ağırlıklı olmak üzere iki farklı yöntem içerir. Her iki yöntem de Hoeffding Eşitsizliğine dayanmaktadır.

2.4.3.1. HDDM-A (average)

HDDM-A, veri akışlarında ani kavram kaymalarını tespit etmek için kullanılır. Basit hareketli ortalama kullanarak veri akışındaki değişiklikleri izler ve Hoeffding eşitsizliğine dayanarak önemli değişiklikleri tespit eder.

DDM'e benzer bir şekilde uyarı ve kavram kayması için iki farklı güven seviyesi belirlenir. Kavram kaymasını tespit etmek için α_D , uyarı durumunun tespit etmek için α_W güven seviyeleri belirlenir. Toplam örnek sayısı n ve her bir yeni örnek için $c = \sum_{i=1}^n x_i$ kümülatif toplam hesaplanır. Veri akışı iki pencereye bölünür: minimum pencere (n_{min}, c_{min}) ve maksimum pencere (n_{maks}, c_{maks}) . Bu pencereler, verinin geçmiş ve güncel durumunu karşılaştırmak için kullanılır. Minimum ve maksimum pencere değerleri başlangıç durumundaysa bunlar güncellenir (eğer $n_{min} = 0$ ise $n_{min} = n$, $c_{min} = c$ eğer $n_{maks} = 0$ ise $n_{maks} = n$, $c_{maks} = c$).

Hoeffding Eşitsizliği kullanılarak minimum pencere için hata sınırı ve toplam örnek sayısı için hata sınırları hesaplanır:

$$\epsilon_{\alpha_D} = \sqrt{\frac{1}{2n} \ln \left(\frac{1}{\alpha_D} \right)}, \epsilon_{\alpha_{D1}} = \sqrt{\frac{1}{2n_{min}} \ln \left(\frac{1}{\alpha_D} \right)}, \epsilon_{\alpha_{D2}} = \sqrt{\frac{1}{2n_{maks}} \ln \left(\frac{1}{\alpha_D} \right)} \quad (2.5)$$

Bu sınırlar kullanılarak n_{min} , c_{min} , n_{maks} , c_{maks} değerleri aşağıdaki gibi güncellenir;

$$\text{Eğer } \frac{c_{min}}{n_{min}} + \epsilon_{\alpha_{D1}} \geq \frac{c}{n} + \epsilon_{\alpha_D} \text{ ise } c_{min} = c, n_{min} = n \quad (2.6)$$

$$\text{Eğer } \frac{c_{maks}}{n_{maks}} - \epsilon_{\alpha_{D2}} \leq \frac{c}{n} - \epsilon_{\alpha_D} \text{ ise } c_{maks} = c, n_{maks} = n \quad (2.7)$$

$$\frac{c}{n} - \frac{c_{min}}{n_{min}} \geq \sqrt{\frac{(n - n_{min})}{n_{min}} \frac{1}{2n} \ln \ln \left(\frac{2}{\alpha} \right)} \quad (2.8)$$

$$\frac{c_{maks}}{n_{maks}} - \frac{c}{n} \geq \sqrt{\frac{(n - n_{maks})}{n_{maks}} \frac{1}{2n} \ln \ln \left(\frac{2}{\alpha} \right)} \quad (2.9)$$

Denklem 2.8 ya da 2.9'daki koşullar sağlandığında, α yerine α_D kullanıldığında kavram kayması, α_w kullanıldığında ise uyarı durumu ortaya çıkmış olur.

2.4.3.2.HDDM-W (*weighted*)

HDDM-W, veri akışında kavram kaymalarını tespit etmek için ağırlıklı hareketli ortalamalar (EWMA - Exponentially Weighted Moving Average) kullanan bir algoritmadır. Bu algoritma, veri akışında meydana gelen ortalama değişiklikleri izler ve Hoeffding eşitsizliğini kullanarak bu değişikliklerin anlamlı olup olmadığını belirler. λ EMWA istatistiği için kullanılan bozulma parametresi olup daha küçük değerler için son gelen gözlemlere daha az ağırlık verir ve $0 \leq \lambda \leq 1$ değerlerini alır. $\hat{\mu}_{EWMA} = \lambda x_i + (1 - \lambda)\hat{\mu}_{EWMA}$ şeklinde hesaplanır. Benzer şekilde kavram kayması ve uyarı durumu için ayrı ayrı α değerinin belirlenmesi gerekmektedir.

HDDM-A genel olarak ani kavram kaymasının tespitinde daha etkinken HDDM-W ise kademeli kavram kaymasının tespitinde daha iyi performans göstermektedir. HDDM algoritmaları karşılaştırılan gözlemler için herhangi bir dağılım varsayımı yapmaz. Değişkenler $[a, b]$ aralığında değerler alabilir ve bunun üzerine Hoeffding eşitsizliği kullanılabilir ancak uygulamalarda sıkça kullanılan scikit-multiflow, river gibi

Python modüllerinde DDM ve EDDM'e benzer şekilde yanıt değişkeninin doğru tahmin edilip edilmediği üzerinden kavram kayması tespit edilmeye çalışılmıştır.

2.4.4. Uyarlanabilir pencere yöntemi (ADWIN – *adaptive windowing*)

ADWIN, veri akışlarında zamanla değişen dağılımları ve kavram kaymalarını tespit etmek için kullanılan bir algoritmadır (Bifet & Gavalda, 2007). Bu algoritma, veri akışlarının zaman içindeki değişim hızına göre pencere boyutunu otomatik olarak ayarlar. Kavram kayması tespit edilmediğinde pencere boyutu büyürken, değişim gerçekleştiğinde pencere boyutu küçülerek eski verileri atar. ADWIN algoritması, veri akışındaki iki alt pencerenin ortalamalarını karşılaştırarak çalışır. Eğer bu iki alt pencerenin ortalamaları belirli bir eşik değerinden (ϵ_{cut}) fazla farklılık gösterirse, bu durum veri akışında bir değişiklik olduğunu gösterir ve pencere boyutu buna göre ayarlanır.

Algoritma, en son okunan verileri içeren bir pencere (W) tutar. Her yeni veri eklendiğinde, pencerenin başına eklenir. Pencere W_0 ve W_1 olarak iki alt pencereye bölünür. W_0 penceresinin ortalaması $\hat{\mu}_{W_0}$ ve W_1 penceresinin ortalaması $\hat{\mu}_{W_1}$ karşılaştırılır. Eğer $|\hat{\mu}_{W_0} - \hat{\mu}_{W_1}| \geq \epsilon_{cut}$ ise kavram kayması tespit edilmiş olunur ve eski veriler atılarak pencere boyutu küçültülür.

ϵ_{cut} değeri aşağıdaki gibi hesaplanır;

$$m = \frac{1}{\frac{1}{n_0} + \frac{1}{n_1}} \quad (2.10)$$

$$\delta' = \frac{\delta}{n} \quad (2.11)$$

$$\epsilon_{cut} = \sqrt{\frac{1}{2m} \ln \left(\frac{4}{\delta'} \right)} \quad (2.12)$$

Burada, n_0 ve n_1 sırasıyla W_0 ve W_1 pencerelerinin uzunluklarıdır, $n = n_0 + n_1$ ise W penceresinin uzunluğudur. δ kullanıcı tarafından belirlenen güven aralığıdır. ADWIN yanıt değişkeni ya da bağımsız değişkenler için uygulanabilir. Tahmin edilen yanıt değişkeninin gerçek değerini beklemeden bağımsız değişkenler üzerinde kullanılarak, gerçek değerler gelmeden de veri kayması tespitinde kullanılmaktadır.

2.4.5. Kolmogorov-Smirnov pencereleme yöntemi (KSWIN – *Kolmogorov-Smirnov windowing*)

KSWIN, veri akışlarında kavram kaymalarını tespit etmek için kullanılan parametrik olmayan istatistiksel bir yöntemdir (Raab vd., 2020). Bu yöntem, Kolmogorov-Smirnov testini (KS testi) kullanarak yeni veriler ile geçmiş veriler arasındaki istatistiksel farkları tespit eder.

Sürekli olarak en son n veri noktasını tutan kayar bir pencere (Ψ) kullanarak çalışır. Ψ 'den iki alt pencere oluşturulur.

R , en son alınan r gözlemi içerir:

$$R = \{x_i \in \Psi \mid i > n - r\} \quad (2.13)$$

W , pencerenin eski kısmından tek düze tek düze rassal seçilen r gözlemi içerir:

$$W = \{x_i \in \Psi \mid i \leq n - r \wedge P(x) = UNIF(x_i \mid 1, n - r)\} \quad (2.14)$$

Burada $|W| = |R| = r$ dir. Daha sonra Kolmogorov-Smirnov (KS) testi, R ve W 'nin ampirik kümülatif dağılımlarını karşılaştırmak için uygulanır. Test, bu dağılımlar arasındaki maksimum mutlak farkı hesaplar ($dist_{w,r}$):

$$dist_{w,r} = \sup_x |F_W(x) - F_R(x)| \quad (2.15)$$

Eğer uzaklık krik değeri geçerse (D_α), kavram kaymasına işaret eder:

$$dist_{w,r} > c(\alpha) \sqrt{\frac{n+r}{nr}} = \sqrt{-\frac{1}{2} \ln \alpha} \sqrt{\frac{n+r}{nr}} = \sqrt{-\frac{\ln \alpha}{r}} \quad (2.16)$$

$P(X)$ dağılımı zaman içerisinde değiştiğinde ve $P(y|X)$ aynı kaldığında bu durum sanal kavram kaymasına işaret eder. KSWIN testi, $P(X)$ 'de bir değişiklik olduğunda $P(y|X)$ 'da da bir değişiklik olduğu varsayımı altında kavram kayması tespitinde kullanılmaktadır. KSWIN testi parametrik olmayan bir test olduğundan, takip edilen değişken için herhangi bir dağılım varsayımı yapılmasına gerek yoktur. KSWIN testi yanıt değişkeni ya da bağımsız değişkenler için uygulanabilir. Tahmin edilen yanıt değişkeninin gerçek değerini beklemeden bağımsız değişkenler üzerinde kullanılarak, gerçek değerler gelmeden de veri kayması tespitinde kullanılmaktadır.

2.4.6. Kümülatif toplamlar yöntemi (CUSUM – *cumulative sums*)

İstatistiksel kalite kontrol literatüründe sıkça kullanılan CUSUM, kavram kayması tespitinde de sıkça kullanılan yöntemlerden birisidir (Page, 1957). CUSUM, verilerin ortalamasında meydana gelen küçük ve sürekli değişiklikleri tespit etmek için geliştirilmiş bir tekniktir. Her yeni veri noktası gözlemlenir ve kaydedilir. Gözlemlenen veri noktalarının ortalaması ve sapması hesaplanır. Her yeni veri noktası ile CUSUM değeri güncellenir. CUSUM değeri belirli bir eşiği aştığında, veri setinde anlamlı bir değişiklik olduğu tespit edilir. Testin ana parametrelerinden δ , testin hassasiyetini belirlerken, λ ise değişiklik tespit eşiği olarak kullanılır. Algoritmada ilk başta $n = 1, \underline{x} = 0, S = 0$ olarak belirlenir. Gelen her bir t . gözlem için aşağıdaki işlemler yapılır;

$$\underline{x}_t = x_{ort} + \frac{x_t - \underline{x}_{t-1}}{n} \quad (2.17)$$

$$S_t = maks(0, S_{t-1} + x_t - \underline{x} - \delta) \quad (2.18)$$

$S_t > \lambda$ durumunda kavram kayması tespit edildiğini gösterir.

2.4.7. Page Hinkley testi (PH)

PH, CUSUM'a benzer bir şekilde veri akışlarında ortalama değerlerdeki değişiklikleri tespit etmek için kullanılan bir yöntemdir (Sebastião & Fernandes, 2017). Bu yöntem, belirli bir gözlem süresi boyunca elde edilen verilerin ortalamasının sabit kalıp kalmadığını belirlemek amacıyla geliştirilmiştir. Temel farklılık, α unutma faktörü, gözlemlenen değer ve ortalama arasında ağırlıklandırma yapar ve bu sayede eski verilerin etkisi azaltılır. Algoritmada ilk başta $n = 1, x_{ort} = 0, S = 0$ olarak belirlenir. Gelen her bir t . gözlem için aşağıdaki işlemler yapılır;

$$\underline{x}_t = x_{ort} + \frac{x_t - \underline{x}_{t-1}}{n} \quad (2.19)$$

$$S_t = maks(0, \alpha * S_{t-1} + x_t - \underline{x} - \delta) \quad (2.20)$$

$S_t > \lambda$ durumunda kavram kayması tespit edildiğini gösterir.

PH, KSWIN testi gibi bağımsız değişkenler ya da yanıt değişkenin dağılımında bir değişiklik olup olmadığını test etmek için kullanılabilir. Kavram kaymasının tespiti için

modelin tahmin ettiđi gözlemler için yanıt deđişkeninin gerçek deđerini beklemek gerekmez. PH testinde uyarı durumu bulunmaz.



3. MATERYAL VE YÖNTEM

İstatistiksel kavram kayması tespit yöntemleri genel olarak sonuçlar üzerinden kavram kayması tespit etmektedir. Bazı testler ise sadece bağımsız değişken ya da yanıt değişkeninin dağılımı üzerinden kavram kaymasını tespit eder. Bu durumda modelin tahmin değerleri ve bağımsız değişkenler arasındaki ilişki incelenemez. Bu ilişkinin gözlemlenmesi ve bu ilişkideki değişiklik üzerinden kavram kaymasını tespit üzere açıklanabilir yeni bir yöntem geliştirilmiştir. Bu yöntem aşağıdaki bölümlerde tartışılmıştır.

3.1. Açıklanabilir Yapay Zeka (XAI – eXplainable Artificial Intelligence)

Yorumlanabilirlik, takip edilebilirlik, güvenilirlik ve artan etik sorgulamadan ötürü açıklanabilir yapay zekâ (AYZ), Yapay Zekâ kullanan bir çok alanda zorunluluk haline gelmiştir. Limitleri anlaşılabilen, tartışılabilen bir sistem inandırıcılığı olmayan daha “doğru” sonuçlar üreten bir sistemden daha değerlidir.

GDPR (2016), (*General Data Protection Regulation*), Türkçesiyle Genel Veri Koruma Yönetmeliği, Avrupa Birliği (AB) tarafından 25 Mayıs 2018 tarihinde yürürlüğe giren ve bireylerin kişisel verilerinin korunmasını amaçlayan bir yasal düzenlemedir. GDPR, AB'deki bireylerin kişisel verilerini işleyen tüm kuruluşlar için bağlayıcıdır, bu kuruluşlar AB içinde yer alsın veya almasın. GDPR'ın veri koruma ve şeffaflık gereksinimleri ile AYZ'nin sağladığı şeffaflık ve hesap verebilirlik, veri sahiplerinin haklarını korumak ve otomatik karar verme süreçlerinin adil ve anlaşılır olmasını sağlamak açısından birbirini tamamlar niteliktedir.

Kısmi Bağımlılık Profili (PDP - *Partial Dependence Profile*), Değişken Önem Değeri (*Variable Importance Measure*), Shapley Değeri ve Ceteris Paribus genel olarak modelin, modeldeki değişkenlerin, modeldeki gözlem değerlerinin açıklanmasına imkân sunar. Özellikle kara-kutu (*black-box*) modellerin nasıl karar verdiğini anlamak için AYZ araçları kullanılır. Günümüzde bu araçların kullanım sıklığı ve önemi her geçen gün artmaktadır.

Makine öğrenmesinde, birçok durumda, yanıt değişkenin, bağımsız bir değişkenle nasıl ilişkili olduğunu anlamak istendiğinde Yerel Bağımlılık Profili (*Local-Dependence*

Profile), Birikmiş Yerel Profili (*Accumulated-Local Profile*) ve Kısmi Bağımlılık Profili (*Partial-Dependence profile*) gibi yöntemler kullanılabilir.

3.2. Ceteris-Paribus Profilleri (CP) ve Kısmi Bağımlılık Profilleri (PDP- Partial Dependence Profiles)

Ceteris-paribus (CP) profilleri, bir modelin tek bir bağımsız değişkenin değeri değiştiğinde nasıl tepki verdiğini ortaya koyar (Biecek & Burzykowski, 2021). Temel olarak, CP profilleri, yanıt değişkenin koşullu beklentisinin belirli bir açıklayıcı değişkenin değerlerine nasıl bağlı olduğunu ortaya koyar. $\underline{x}_i$ bir veri kümesindeki i . gözleme karşılık gelen açıklayıcı değişkenlerin değer vektörünü gösterir. Herhangi bir gözlemle bağlantılı olmayan rastgele değerlere sahip bir vektör $\underline{x}_*$ ile gösterilir. $\underline{x}_*^j$ ifadesi $\underline{x}_*$ vektöründen j . Bağımsız değişkenin değerini ifade eder. $\underline{x}_*^{-j}$, $\underline{x}_*$ vektöründen j . bağımsız değişkenin çıkarılması sonucu oluşan vektörü ifade eder. $\underline{x}_*^{j|z}$ ise $\underline{x}_*$ vektörünün j . elemanın değerini z ile değiştirme sonucu oluşan vektörü ifade eder.

f modeli için, tek boyutlu CP h fonksiyonu şu şekilde tanımlanır;

$$h_{\underline{x}_*}^{f,j}(z) \equiv f(\underline{x}_*^{j|z}) \quad (3.1)$$

CP profili, Y yanıt değişkeninin j . bağımsız değişkeninin z değerine bağlı olarak (yaklaşık olarak) koşullu beklenen değerinin bağımlılığını tanımlayan bir fonksiyondur. z değişkenin tüm gözlemlenen aralığında değerler alırken, diğer tüm bağımsız değişkenlerin değerleri $\underline{x}_*$ tarafından belirlenen değerlerde sabit tutulur.


Model f ve açıklayıcı değişken X^j için z değerindeki bir PDP değeri şu şekilde tanımlanır (Biecek & Burzykowski, 2021).;

$$g_{PD}^j(z) = E_{X^{-j}}\{f(X^{j|z})\} \quad (3.2)$$

Bu, X^j değerinin z olarak sabitlendiğinde model tahminlerinin beklenen değeridir. Bu beklenen değer, X^{-j} 'nin marjinal dağılımı yani X^j dışındaki tüm bağımsız değişkenlerin ortak dağılımı üzerinde hesaplanır. Aynı zamanda PDP, X^j için CP profilinin X^{-j} dağılımı üzerindeki beklenen değeridir.

X^{-j} 'nin gerçek dağılımı bilinmediğinde, n adet gözlem için, CP profillerinin ortalaması PDP için bir tahminci için kullanılır;

$$\hat{g}_{PD}^j(z) = \frac{1}{n} \sum_{i=1}^n f(x_i^{j|=z}) \quad (3.3)$$



Şekil 3.1. Örnek PDP

Şekil 3.1.'de Iris veri seti üzerinde bir rassal orman modeli kullanılarak Petal Length ve Petal Width özelliklerinin, Species değişkeninin Setosa, Versicolor ve Virginica düzeyleri için yanıt değişken olan Iris bitkisinin türü üzerindeki etkisi görselleştirilmiştir. Bu sayede, her bir düzeydeki Species değişkeninin değerleri değiştiğinde, Petal Length ve Petal Width özelliklerinin Iris bitkisinin türünü tahmin etmekte kullanılan model üzerindeki etkisi görsel olarak gösterilmiştir.

3.3. Profil Farklılıklarının Ölçülmesi

Profil farklılıklarının ölçülmesi için farklı yaklaşımlar mevcuttur. Literatürde bu profil farklılıkları aynı veri seti üzerinde farklı modeller eğitildiğinde, model davranışlarının karşılaştırılması için kullanılmıştır (Kobylińska vd., 2023).

Model $f \in F$ ve bağımsız değişken $j \in \{1, 2, \dots, p\}$ olmak üzere, profil fonksiyonu $g_f^j: D_j \rightarrow R$ j . değişkenin değerleri ile f modelinin tahmin değerleri arasındaki ilişkiyi ifade eder.

$$D_j = \left[\min_{i \in \{1, 2, \dots, n\}} x_i^{(j)}, \max_{i \in \{1, 2, \dots, n\}} x_i^{(j)} \right] \quad (3.4)$$

İki profil arasındaki fark farklı yöntemlerle ölçülebilir, fonksiyonel analizde sıkça kullanılan L^2 Öklidyen uzaklık iki profil için şu şekilde tanımlanır;

$$d_{L^2}(g_{f_1}^j, g_{f_2}^j) = \sqrt{\int_{D_j} \left(g_{f_1}^j(z) - g_{f_2}^j(z) \right)^2 dz} \quad (3.5)$$

burada, $g_{f_1}^j$ 1. profili, $g_{f_2}^j$ ise 2. profili temsil eder.

Birinci dereceden türevler arasındaki L^2 uzunluğu, profillerin şeklini dikkate alır ve şu şekilde hesaplanır;

$$d_{L^2, der}(g_{f_1}^j, g_{f_2}^j) = \sqrt{\int_{D_j} \left(\frac{\partial}{\partial X^{(j)}} g_{f_1}^j(z) - \frac{\partial}{\partial X^{(j)}} g_{f_2}^j(z) \right)^2 dz} \quad (3.6)$$

Profil Farklılığı İndeksi (PDI) profillerdeki değişim oranlarını göz ardı eden bir profil yükselirken diğerinin alçalıp alçalmadığını ayırt etmeye odaklanır.

$$PDI(g_{f_1}^j, g_{f_2}^j) = \frac{1}{\sup D_j - \inf D_j} \int_{D_j} \left[\operatorname{sgn} \left(\frac{\partial}{\partial X^{(j)}} g_{f_1}^j(z) \right) \neq \operatorname{sgn} \left(\frac{\partial}{\partial X^{(j)}} g_{f_2}^j(z) \right) \right] dz \quad (3.7)$$

$$\widehat{PDI}(\widehat{g_{f_1}^j}, \widehat{g_{f_2}^j}) = \frac{1}{m} \sum_{i=1}^m I[\operatorname{sgn}(\operatorname{der}(\widehat{g_{f_1}^j}))[i] \neq \operatorname{sgn}(\operatorname{der}(\widehat{g_{f_2}^j}))[i]] \quad (3.8)$$

burada, $\operatorname{der}(\widehat{g_{f_k}^j})$, k . modelin PDP'sinin ardışık m noktasında belirlenen türevler vektörüdür ve $\operatorname{der}(\widehat{g_{f_k}^j})[i]$ bu vektörün i . elemanıdır. PDI değeri $[0, 1]$ arasında değerler

alır ve 0 iki profil arasında herhangi bir farklılık olmadığını ifade ederken, 1 değeri her i noktasında bir profilin artarken diğer profilin azaldığını ya da tersi durumu ifade eder.

3.4. Metriklerin Hesaplanması

Metrikler hesaplanmadan önce PDP'lerin elde edilmesi gerekir, bu çalışmada R programlama dilinde farklı AYZ araçlarına sahip DALEX (Biecek, 2018) paketinde bulunan `model_profile` fonksiyonu kullanılarak bu değerler elde edilmiştir.

PDI, d_{L2} (L2) ve $d_{L2,der}$ (L2Der) metrikleri profil farklılığının ölçülmesine olanak tanır. Yeni gelen verilerde bağımsız değişkenler, eğitim ve test setinde bulunan bağımsız değişkenlerin değerlerinden farklı olabilir. Bu durumda, iki PDP eğrisi doğrudan aynı x değerlerine sahip olmadıkları için PDI, L2 ve L2Der hesaplanamaz. Bu hesaplamaların yapılabilmesi için doğrusal interpolasyon kullanılmıştır. Bu süreçte, yeni veriler için hesaplanan PDP_2 'nin x değerleri alınır ve eski verilerle oluşturulmuş PDP_1 'in x ve y değerlerine dayanarak PDP_2 'nin x değerlerine karşılık gelen y değerleri hesaplanır. Doğrusal interpolasyon, PDP_1 'in x ve y değerleri arasında doğrusal bir çizgi çizerek ara değerleri tahmin eder. Özellikle, PDP_2 'nin x değerleri PDP_1 'in x aralığının dışındaysa, en yakın uç noktadaki y değeri kullanılır. Sonuç olarak, doğrusal interpolasyon işlemi sayesinde PDP_1 'in y değerleri, PDP_2 'nin x değerlerine göre yeniden hesaplanır ve iki profil aynı x noktalarında karşılaştırılabilir hale getirilmiştir.

İnterpolasyon uygulandıktan sonra `doremi` R paketinde (Denis vd., 2021) bulunan `calculate.gold` fonksiyonu ile PDP_1 ve PDP_2 için türevler hesaplanır. `stats` paketinde bulunan `spline` fonksiyonu kullanılarak kübik spline interpolasyonu uygulanır. Bunun nedeni daha pürüzsüz bir eğri oluşturulmasıdır. Nümerik hesaplamalar sonucunda 0'a çok yakın ama pozitif ya da negatif değerler çıkabilmektedir. Bu da PDI hesabında yanlış sonuçlar elde edilmesine neden olabilir. Belli bir eşik değerin altında kalan değerlere 0 atanır (varsayılan olarak hesaplanan türev değerlerinin maksimumunun 0.01'inden küçük olanlara). Bu işlemlerden sonra eğrilerin türev işaretlerinin eşit olup olmaması karşılaştırılır ve bu şekilde PDI değeri elde edilir. Yöntemde `fda.usc` (Febrero-Bande & De La Fuente, 2012) paketinde bulunan `metric.lp` fonksiyonu ile L2, yine aynı pakette bulunan `semimetric.deriv` fonksiyonu ile de L2Der hesaplanır.

3.5. Profil Kayması Tespiti (PDD – Profile Drift Detection)

PDP karşılaştırmalarında L2 uzaklık, birinci dereceden türevler arasındaki uzaklık L2Der ve PDI yöntemlerinin birlikte kullanılması, profillerin çeşitli yönlerini kapsamlı bir şekilde değerlendirmeyi sağlar. L2 uzaklık, iki profil arasındaki genel farkı ve büyüklüğü ölçer. Bu yöntem, profillerin tüm noktaları boyunca değerler arasındaki kare farklarını alarak, profillerin genel benzerliklerini veya farklılıklarını değerlendirerek PDP'lerin genel şekilleri arasındaki mesafeyi belirler ve profillerin toplam yapısal benzerlikleri hakkında bilgi sağlar.

Birinci dereceden türevler arasındaki L2Der yöntemi ise, profillerin türevlerini karşılaştırarak profillerin değişim hızlarını ve bu değişimlerin şiddetini analiz eder. Türevler arasındaki bu uzaklık, profillerin eğilimlerindeki farklılıkları ve bu farklılıkların şiddetini belirlemekte daha etkilidir. Türevlerin karşılaştırılması, profillerin eğimlerinde ve yerel değişimlerinde meydana gelen farklılıkları ortaya çıkarır. Bu yöntem, profillerin sadece genel şekillerini değil, aynı zamanda lokal varyasyonlarını ve dinamik davranışlarını da anlamayı sağlar. Profillerin belirli noktalarındaki ani değişimlerin veya eğim farklarının tespit edilmesine olanak tanır.

PDI ise profillerin aynı veri noktalarında artış veya azalış gösterip göstermediğine odaklanır. PDI, iki profilin yönelimlerdeki değişiklikleri dikkate alarak profillerin davranışlarının benzerliğini değerlendirir. Bu indeks, profillerdeki değişim oranlarını göz ardı ederek bir profilin yükselirken diğerrinin düşüp düşmediğini belirlemeye odaklanır. PDI, profillerin yönelimlerdeki farklılıkları sayısal olarak ifade eder ve profillerin zıt veya benzer davranışlarını ortaya koyar. Bu üç yöntemin birlikte kullanımı, profiller arasındaki genel uzaklığı, değişim hızlarını ve yönelimlerdeki farklılıkları kapsamlı bir şekilde ölçme ve analiz etme imkânı sunar. Böylece, profillerin hem genel benzerliklerini hem de farklı veri noktalarındaki davranışlarını anlamayı mümkün kılar. PDP'lerdeki farkın bu üç farklı metrik ile incelenmesi bu çalışmada Profil Kayması Tespiti (PDD- *Profile Drift Detection*) olarak adlandırılmıştır.

Input: Eğitim ve test setleri

Output: *test_doğruluk eğitim_doğruluk, kayma_sayısı, doğruluk*

```
1 Eğitim ve test setlerinin büyüklüklerini ilgili yığın sayısına göre hesapla;
2 model ← eğitim seti üzerinde eğitilmiş rassal orman modeli;
3 test_doğruluk eğitim_doğruluk ← Eğitim ve test doğruluk oranlarını
   hesapla;
4 değişken ← en önemli değişkeni bul;
5 profile1_train ← eğitim setindeki değişken için PDP hesapla;
6 profile1 ← test seti setindeki değişken için PDP hesapla;
7 Hesaplanan PDP'ler ile grafik oluştur kaydet;
8 PDI, L2, L2Der ← profile1_train ve profile1 ile hesapla;
9 pdi_esik ← PDI;
10 l2_esik ← L2;
11 l2der_esik ← L2Der;
12 for her yeni yığın in test seti uzunluğundan veri seti uzunluğuna, artış
   adımı olarak yığın büyüklüğü do
13   doğruluk_listesi ← Model ile yeni yığın için doğruluk hesapla ve
     doğruluk listesine kaydet;
14   profile2 ← yeni yığın için değişken için PDP hesapla;
15   PDI, L2, L2Der ← profile1 ve profile2 ile hesapla;
16   pdi_gecici ← PDI;
17   l2_gecici ← L2;
18   l2der_gecici ← L2Der;
19   if pdi_gecici > pdi_esik and l2_gecici > l2_esik and
     l2der_gecici > l2der_esik then
20     kayma_sayısı ← kayma_sayısı + 1;
21     pdi_esik ← pdi_gecici;
22     l2_esik ← l2_gecici;
23     l2der_esik ← l2der_gecici;
24     Önceki verinin üzerine yeni yığındaki veriyi ekle;
25     Yeni veri ile modeli eğit ve güncelle;
26     profile1 ← yeni model ile birleştirilmiş veri için değişken için
       PDP hesapla;
27     profile1 ve profile2 için grafik oluştur ve kaydet;
28   end
29 end
30 return (test_doğruluk eğitim_doğruluk, kayma_sayısı,
   doğruluk = ortalama(doğruluk_listesi))
```

Şekil 3.2. PDD algoritması

PDD'nin kullandığı 3 farklı metrik (PDI, L2, L2Der) parametre olarak belirlenebilir. Ön çalışmalarda (Dar & Cavus, 2023; Dar & Cavus 2024) sadece PDI metriği kullanılarak kavram kayması tespit edilmeye çalışılmıştır ancak PDI metriğinin bazı durumlarda kavram kayması tespitinde tek başına yetersiz olduğu görülmüştür. PDD ise PDI'a ek olarak L2 ve L2Der metrikleri de ele alınmıştır. Algoritmada 3 metrik için belirlenen eşik değerlerin “kabul edilebilir” sapmalara uygun olması gerekir. Şekil 3.2.'de eğitim-test verileri üzerinden hesaplanan 3 metrik yeni gelen yığından elde edilen metriklerle karşılaştırılır ve 3 metriğin de büyük olması durumu kavram kayması olarak

belirlenir. Ancak veri setinin yapısına göre, gelen yeni veriler (dolayısıyla PDP'ler) benzer şekillerde olup birbirinden dikey eksenle uzak olabilir bu durumda PDI metriğinin kullanılması yanlış-negatif sonuçları arttırabilir. Eğitim-test verisinde yüksek değerlere sahip metrikler ise yeni gelen yığınlarda yanlış-pozitif değerler üretebilir.

Benzer şekilde istatistiksel testler de farklı hassasiyet parametrelerine sahiptir. Örneğin, KSWIN testinde α , pencere büyüklüğü, istatistik büyüklüğü gibi parametreler mevcuttur. Benzer şekilde PH 4, HDDM-W, HDDM-A, EDDM ve DDM 3 parametreye sahiptir. PDD ve istatistiksel testlerin parametrelerinin değiştirilmesi kayma tespiti hassasiyetini etkiler. Bölüm 4.'de bulunan uygulamalarda istatistiksel testler varsayılan parametreleri ile kullanılmıştır. PDD ise 3 uygulamada varsayılan parametreleriyle, 3 uygulamada ise parametreleri değiştirilerek kullanılmıştır.

3.6. datadriftR Paketi

Günümüzde makine öğrenmesi modelleri canlı sistemlere entegre edilmektedir. MLOps (*Machine Learning Operations*) kavramı entegrasyonun daha güvenilir ve verimli şekilde yapılmasını ve sürdürülmesini amaçlayan bir paradigmadır (Alla vd., 2021). Model izleme kavramı MLOps süreçlerinden birisidir. Python dilinde model izlemeye yönelik farklı modüller mevcuttur. Evidently AI (2020) Airflow, MLflow gibi teknolojilerle kolayca entegre edilerek model izlemede sıkça kullanılan modüllerden birisidir. Benzer şekilde model izleme ve çevrimiçi öğrenme algoritmalarının bulunduğu River (Montiel vd., 2021) paketi bulunmaktadır. MLOps alanında R'da *vetiver* (Silge, 2023) paketi bulunmaktadır. Ancak model izlemede, kavram kayması tespiti gibi yöntemler bakımından zayıftır.

R programlama dilinde makine öğrenmesi alanında çok sayıda paket bulunmaktadır. Veri kayması konusunda da *driftR* paketi bulunmaktadır. Ancak paket sınırlı sayıda yöntem içermekte olup 2. Bölümde bahsedilen istatistiksel testler mevcut değildir ayrıca güncellemeye sahip değildir. Bu çalışma kapsamında bahsedilen istatistiksel testleri uygulamak için paket geliştirilmiştir. Geliştirilen bu pakette HDDM-A, HDDM-W, KSWIN, PH, DDM, EDDM testleri bulunmaktadır. İleride ADWIN, CUSUM gibi sık kullanılan diğer istatistiksel testlerin de pakete eklenmesi planlanmaktadır.

Geliştirilen R paketi (Dar, 2024) The Comprehensive R Archive Network (CRAN)'da yayınlanmıştır. CRAN sayfası ve GitHub kodları EK-1'de verilmiştir. Bu paket R dilinde MLOps süreçlerinde `vetiver` paketi ile uyumlu çalışabilir.



4. UYGULAMALAR

Bu bölümde literatürde sıkça kullanılan sentetik ve gerçek dünya veri setleri kullanılarak klasik yöntemler ve PDD metodu kıyaslanmıştır. Kıyaslamada doğruluk (*accuracy*) ve kayma sayıları kullanılmıştır.

Yeni gelen veri yığınlarında (*batches*), veri yığınlarının modelin eğitilmesi için uygun olup olmadığı belirlenir. Eğitim ve test setleri ile elde edilen PDP'ler üzerinden PDI, L2Der ve L2 hesaplanarak eşik değeri olarak atanır. Eğer bu üç metrik de belirlenen eşik değerlerden yüksek ise yeni gelen veri yığını eğitim setine eklenerek model tekrar eğitilir. Grafiklerde PDD yönteminin kavram kayması tespit ettiği yığın sayıları için, eğitim-test setlerinin PDP eğrileri ve kaymanın tespit edildiği zamandaki PDP grafikleri her veri seti için eklenmiştir. Bu süreç, kavram kaymasını tespit etmeye ve modelin güncel veriye uyum sağlamasına yardımcı olur. Böylece, model sürekli olarak güncellenir ve veri akışındaki değişimlere adapte olabilir.

İstatistiksel testler, gelen veri yığındaki yanıt değişkeninin doğru tahmin edilip edilmediğini test ederek çalışmaktadır. Her yeni gelen veri yığını için tahmin değerleri elde edilir ve gerçek değerlerle test edilir. Eğer bu veri yığında kavram kayması tespit edilirse, benzer şekilde gelen veriler eğitim verisine eklenir ve model tekrar eğitilir. Model olarak ağaç sayısı 50 ve diğer hiper-parametreleri varsayılan olan rassal orman modeli kullanılmıştır.

Her deney için, kullanılan kavram kayması tespit yöntemi, yığın sayıları, yığın boyutuyla aynı boyuttaki test seti ve eğitim setinin boyutu, ilgili yığın sayısı için tespit edilen kayma sayısı ve eğitim-test setlerindeki model performansı tablo olarak verilmiştir.

4.1. SEA Veri Seti

SEA veri seti, kavram kayması problemlerini incelemek ve algoritmaların performansını değerlendirmek amacıyla sentetik olarak üretilmiş bir veri setidir. Literatürde büyük ölçekli sınıflandırma problemleri ve akış verilerinde etkin bir şekilde kullanılmaktadır (Street & Kim, 2001).

SEA sentetik bir veri setidir. 3 bağımsız değişken UNIF(0,10) dağılımına sahiptir. Bu bağımsız değişkenlerden ilk 2 değişken bağımlı değişken ile ilişkilidir. Buradaki deneyde iki farklı kavram belirlenmiştir. Yanıt değişkeni eğer $V1 + V2 <$

8 ise 1 değilse 0 değerlerini almaktadır. Veri setinde 30952 adet 0 ve 19048 adet 1 sınıfına ait gözlem bulunmaktadır.

Tablo 4.1. SEA veri seti için deney sonuçları


Yöntem	Yığın Sayısı							
	3		5		10		15	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,8212	0	0,8508	0	0,8264	1	0,8406	1
HDDM-W	0,8212	1	0,8508	1	0,8257	3	0,8392	3
KSWIN	0,8129	3	0,8490	5	0,8268	10	0,8406	15
PH	0,8212	0	0,8508	1	0,8298	1	0,8410	1
DDM	0,8212	0	0,8515	1	0,8267	0	0,8394	0
EDDM	0,8129	3	0,8490	5	0,8268	10	0,8406	15
PDD	0,8129	3	0,8210	2	0,8285	1	0,8311	2
Test	0,8205		0,8502		0,8537		0,8900	
Eğitim	0,9988		0,9990		0,9991		0,9990	
Eğitim-Test	26666	6667	20000	5000	13332	3334	10000	2500

Yöntem	Yığın Sayısı					
	20		25		30	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,8432	2	0,8363	2	0,8384	2
HDDM-W	0,8412	4	0,8343	3	0,8362	3
KSWIN	0,8421	20	0,8372	25	0,8387	29
PH	0,8417	3	0,8374	2	0,8393	3
DDM	0,8430	3	0,8355	1	0,8379	3
EDDM	0,8423	19	0,8372	25	0,8390	13
PDD	0,8338	2	0,8356	2	0,8355	1
Test	0,8896		0,8795		0,9007	
Eğitim	0,9989		0,9988		0,9991	
Eğitim-Test	8000	2000	6666	1667	5713	1429

SEA veri seti için sonuçlar Tablo 4.1.'de verilmiştir, çalışmada kullanılan HDDM-A, HDDM-W, KSWIN, PH, DDM, EDDM ve PDD yöntemlerinin performansları, farklı yığın sayılarında doğruluk ve kayma sayısı açısından değerlendirilmiştir. Örneğin yığın sayısının 20 olduğu durumda eğitim setinde 8000 adet, test setinde ise 2000 adet gözlem bulunmaktadır. Test setinde ulaşılan doğruluk değeri 0,8896 ve eğitim setindeki doğruluk değeri ise 0,9989'dur. Yeni gelen yığın boyutları test setinin boyutuna eşit olup 2000'dir. 20 adet yığın geldiği durumda HDDM-A, 2 adet kavram kayması tespit etmiştir. Her kavram kayması tespit edildiğinde, model bu yığındaki verileri eğitim ve test seti birleştirildikten sonra bunların üzerine eklemiştir, yani 1. kayma tespit edildikten sonra


model 12000 (10000 + 2000) adet gözlem ile eğitilmiştir. 2. kayma tespit edildiğinde ise model 14000 (12000 + 2000) gözlem ile eğitilmiştir.

HDDM-A ve HDDM-W yöntemleri genel olarak yüksek doğruluk oranlarına sahiptir, ancak HDDM-W daha fazla kayma tespit ederken, HDDM-A daha az kayma tespit etmektedir. KSWIN yöntemi, neredeyse her zaman yığın sayısına yakın kayma sayısı tespit etmiştir ve bu veri seti özelinde KSWIN oldukça hassastır. PH ve DDM yöntemleri, yüksek doğruluk oranlarına sahip olup genellikle düşük kayma sayısı ile stabil performans sergilemektedir. EDDM yöntemi de yüksek sayıda kayma tespit etmiştir, özellikle büyük yığın sayılarında bu durum daha belirgindir ancak yığın sayısı 30 olduğunda diğer yığın sayılarındaki orandan daha düşük sayıda kavram kayması tespit etmiştir. PDD yöntemi ise diğer yöntemlere göre biraz daha düşük doğruluk oranlarına sahip olmakla birlikte, tutarlı ve düşük sayıda kayma tespiti ile öne çıkmaktadır. Yığın sayısının artması genellikle doğruluk oranlarını artırmakta, ancak kayma tespit eden yöntemlerde (özellikle KSWIN ve EDDM) kayma sayısının da artmasına neden olmaktadır. Sonuç olarak, HDDM-A ve PH yöntemleri düşük sayıda kayma sayısı ve yüksek doğruluk sağladıkları için tercih edilebilirken, KSWIN ve EDDM yöntemleri yüksek sayıda kayma tespit etmeleri nedeniyle daha dinamik güncellemeler gerektirebilir. PDD yöntemi ise düşük kayma ve makul doğruluk oranları ile stabil bir seçenek olarak değerlendirilebilir. Aşağıda PDD'nin kayma tespit ettiği anlardaki PDP grafikleri verilmiştir.




Şekil 4.1. SEA veri seti için yığın-3 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.85 - PDI: 0.19 - L2Der: 0.12 - L2: 0.04




İndeks: 1 - Doğruluk: 0.85 - PDI: 0.26 - L2Der: 0.22 - L2: 0.09




Şekil 4.2. SEA veri seti için yığın-5 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.85 - PDI: 0.19 - L2Der: 0.12 - L2: 0.04




İndeks: 1 - Doğruluk: 0.85 - PDI: 0.26 - L2Der: 0.22 - L2: 0.09




Şekil 4.3. SEA veri seti için yığın-10 üzerinde PDD'nin kavram kayması tespiti


Test - Doğruluk: 0.89 - PDI: 0.14 - L2Der: 0.13 - L2: 0.03



İndeks: 1 - Doğruluk: 0.85 - PDI: 0.19 - L2Der: 0.16 - L2: 0.06




İndeks: 2 - Doğruluk: 0.85 - PDI: 0.22 - L2Der: 0.17 - L2: 0.12




Şekil 4.4. SEA veri seti için yığın-15 üzerinde PDD'nin kavram kayması tespiti


Test - Doğruluk: 0.89 - PDI: 0.19 - L2Der: 0.12 - L2: 0.04



İndeks: 2 - Doğruluk: 0.85 - PDI: 0.2 - L2Der: 0.18 - L2: 0.14




İndeks: 19 - Doğruluk: 0.82 - PDI: 0.24 - L2Der: 0.18 - L2: 0.16




Şekil 4.5. SEA veri seti için yığın-20 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.88 - PDI: 0.21 - L2Der: 0.07 - L2: 0.06



İndeks: 6 - Doğruluk: 0.85 - PDI: 0.22 - L2Der: 0.2 - L2: 0.1




İndeks: 20 - Doğruluk: 0.81 - PDI: 0.24 - L2Der: 0.32 - L2: 0.22




Şekil 4.6. SEA veri seti için yığın-25 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.9 - PDI: 0.17 - L2Der: 0.1 - L2: 0.05



İndeks: 1 - Doğruluk: 0.89 - PDI: 0.22 - L2Der: 0.29 - L2: 0.1



Şekil 4.7. SEA veri seti için yığın-30 üzerinde PDD'nin kavram kayması tespiti

PDD genel olarak ilk indekslerden itibaren kavram kayması tespit etmiştir. Önemli bir nokta ise bazı yığın sayılarında V1 bazılarında ise V2 değişkeni en önemli değişken

olarak tespit edilmiştir ve gelen yeni yığınlarda bu değişkenler üzerinden hesaplamalar yapılmıştır. Eğitim ve test setlerinde benzer PDP eğrilerine sahip değişkenler için hesaplanan metrikler düşük olduğundan genel olarak yeni gelen yığınlarda kavram kayması tespit edilmiştir (Bkz. Şekil 4.3., 4.4., 4.6.). Klasik istatistiksel yöntemlerden farklı olarak PDD ile kavram kayması tespit edildiğinde veride ne gibi değişiklik olduğu da gözlemlenebilmektedir. Örneğin, Şekil 4.6.'da v_2 değişkeninin 0-5 aralığında yanıt değişkenine katkısı düşerken, 5-10 aralığında aldığı değerlerde büyük bir değişim olmadığı gözlemlenmiştir.

4.2. Hyperplane Veri Seti

Bu çalışmada kullanılan hyperplane sentetik verisi, "Mining time-changing data streams" (Hulten vd., 2001) başlıklı makalede tanımlanan yöntem ile oluşturulmuştur. Bu veri seti, zaman içinde değişen kavramları simüle etmek için kullanılan d-boyutlu uzayda bir hiper düzlemdir. Sentetik veri üretilirken `river` Python modülünde bulunan `synth.Hyperplane` fonksiyonu kullanılmıştır. Her örnek için değişim büyüklüğü `mag_change=0.7` ve `seed = 42` olarak alınmıştır. Veri seti 20.000 gözlem, 2 bağımsız değişken ve iki sınıflı 10032 adet 0 ve 9968 adet 1 bulunan yanıt değişkeninden oluşmaktadır.

Bu veri seti ile yapılan deneyde, kavram kayması tespiti için PDD'de iki farklı yöntem izlenmiştir.

1. PDD, diğer veri setlerinde olduğu gibi yeni gelen yığında hesaplanan 3 metriğin 3'nün de bir önceki hesaplanan metriklerden büyük olduğu durum.
2. PDD2, hesaplanan 3 metriğin 2'sinin bir önceki eşik değerden yüksek olması kavram kayması olarak değerlendirilmiştir.

Tablo 4.2. *Hyperplane veri seti için deney sonuçları*


Yöntem	Yığın Sayısı							
	3		5		10		15	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,7930	1	0,6521	0	0,7834	0	0,7108	1
HDDM-W	0,7930	1	0,8188	1	0,7794	2	0,7955	2
KSWIN	0,8383	3	0,8614	5	0,8219	10	0,8170	12
PH	0,7930	1	0,8188	1	0,7834	0	0,7108	1
DDM	0,7930	1	0,8427	2	0,7834	0	0,7256	1
EDDM	0,8383	3	0,8614	5	0,7834	0	0,8164	12
PDD	0,7927	0	0,8371	1	0,7831	1	0,7320	2
PDD2	0,8378	3	0,8527	3	0,8064	3	0,7320	2
Test	0,7912		0,8306		0,6524		0,6883	
Eğitim	0,9985		0,9986		0,9993		0,9985	
Eğitim-Test	10666	2667	8000	2000	5332	1334	4000	1000

Yöntem	Yığın Sayısı					
	20		25		30	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,6809	1	0,6795	1	0,6267	1
HDDM-W	0,7615	3	0,7342	3	0,7536	6
KSWIN	0,8144	17	0,8023	19	0,7948	22
PH	0,7033	1	0,6949	1	0,6267	1
DDM	0,7290	3	0,6870	2	0,6267	1
EDDM	0,8072	16	0,8006	24	0,7957	24
PDD	0,6639	1	0,6203	1	0,5099	0
PDD2	0,7562	4	0,7537	4	0,7473	6
Test	0,6692		0,5584		0,4799	
Eğitim	0,9984		0,9985		0,9978	
Eğitim-Test	3200	800	2666	667	2285	572

Hyperplane veri seti için sonuçlar Tablo 4.2.'de verilmiştir. HDDM-A yöntemi, genellikle düşük sayıda kayma tespitinde bulunmuştur. Örneğin, yığın sayısı 3 ve 10 olduğunda kayma sayısı sırasıyla 1 ve 0 iken, doğruluk oranları 0.7929 ve 0.7834 olarak gözlemlenmiştir. HDDM-W yöntemi ise daha yüksek doğruluk oranlarına sahip olup, kayma tespit etme konusunda daha hassastır; örneğin, yığın sayısı 10 olduğunda doğruluk oranı 0.7794 iken kayma sayısı 2 olarak tespit edilmiştir. KSWIN yöntemi, yığın sayısına bağlı olarak yüksek kayma tespit etmekte ve bu veri seti özelinde kayma tespitinde oldukça hassas olduğunu göstermektedir. PH yöntemi ise HDDM-A ile hemen hemen aynı sayıda kayma tespit etmiştir ancak HDDM-A'daki model performansına göre nispeten modelin daha iyi performans gösterdiği söylenebilir. EDDM ise KSWIN testine benzer sonuçlara sahiptir ancak genelde yüksek sayıda kayma tespitinde bulunurken yığın


sayısı 10 olduğunda kayma tespiti yapmadığı görülmektedir. PDD ise 3, 5, 10, 15 yığın sayısına sahip deneylerde diğer istatistiksel testlere yakın ya da daha iyi sonuç gösterirken 20, 25 ve özellikle 30 yığın sayısına sahip deneylerde hem kayma tespiti hem de model performansı bakımından kötü performans göstermiştir. PDD2 (iki koşul sağlanması) durumunda ise PDD'ye kıyasla kayma tespiti ve model performansında ciddi bir artış meydana gelmiştir. Yığın sayısı 30 iken PDD hiç kayma tespit etmemişken, PDD2 6 kayma tespit etmiştir. Doğruluk oranı 0,50 iken 0,74 seviyesine çıkmıştır.

PDD2, PDD'ye göre daha fazla kayma tespitinde bulunduğundan dolayı ve benzer PDP eğrilerine sahip oldukları için aşağıda sadece PDD2'ye ait görseller eklenmiştir.




Şekil 4.8. Hyperplane veri seti için yığın-3 üzerinde PDD2'nin kavram kayması tespiti

Test - Doğruluk: 0.83 - PDI: 0.28 - L2Der: 1.42 - L2: 0.04




İndeks: 1 - Doğruluk: 0.79 - PDI: 0.32 - L2Der: 0.4 - L2: 0.04




İndeks: 3 - Doğruluk: 0.83 - PDI: 0.37 - L2Der: 1.07 - L2: 0.04




İndeks: 4 - Doğruluk: 0.86 - PDI: 0.32 - L2Der: 1.09 - L2: 0.05



Şekil 4.9. Hyperplane veri seti için yığın-5 üzerinde PDD2'nin kavram kayması tespiti




Şekil 4.10. *Hyperplane veri seti için yığın-10 üzerinde PDD2'nin kavram kayması tespiti*




Şekil 4.11. Hyperplane veri seti için yığın-15 üzerinde PDD2'nin kavram kayması tespiti


Test - Doğruluk: 0.67 - PDI: 0.12 - L2Der: 1.51 - L2: 0.04




İndeks: 2 - Doğruluk: 0.55 - PDI: 0.19 - L2Der: 0.67 - L2: 0.05




İndeks: 3 - Doğruluk: 0.6 - PDI: 0.27 - L2Der: 1.42 - L2: 0.04



İndeks: 5 - Doğruluk: 0.72 - PDI: 0.23 - L2Der: 1.99 - L2: 0.05




İndeks: 20 - Doğruluk: 0.76 - PDI: 0.26 - L2Der: 1.91 - L2: 0.05




Şekil 4.12. Hyperplane veri seti için yığın-20 üzerinde PDD2'nin kavram kayması tespiti


Test - Doğruluk: 0.56 - PDI: 0.21 - L2Der: 1.15 - L2: 0.05




İndeks: 1 - Doğruluk: 0.6 - PDI: 0.2 - L2Der: 1.17 - L2: 0.06




İndeks: 3 - Doğruluk: 0.67 - PDI: 0.26 - L2Der: 1.76 - L2: 0.04



İndeks: 6 - Doğruluk: 0.61 - PDI: 0.26 - L2Der: 1.84 - L2: 0.05




İndeks: 10 - Doğruluk: 0.78 - PDI: 0.32 - L2Der: 2 - L2: 0.06




Şekil 4.13. *Hyperplane veri seti için yığın-25 üzerinde PDD2'nin kavram kayması tespiti*


Test - Doğruluk: 0.48 - PDI: 0.2 - L2Der: 2 - L2: 0.05




İndeks: 1 - Doğruluk: 0.51 - PDI: 0.21 - L2Der: 1.45 - L2: 0.05




İndeks: 2 - Doğruluk: 0.69 - PDI: 0.21 - L2Der: 1.32 - L2: 0.05




İndeks: 4 - Doğruluk: 0.68 - PDI: 0.24 - L2Der: 1.3 - L2: 0.05




İndeks: 10 - Doğruluk: 0.67 - PDI: 0.27 - L2Der: 1.33 - L2: 0.05



İndeks: 13 - Doğruluk: 0.81 - PDI: 0.3 - L2Der: 1.06 - L2: 0.05



İndeks: 30 - Doğruluk: 0.78 - PDI: 0.31 - L2Der: 1.84 - L2: 0.05



Şekil 4.14. *Hyperplane veri seti için yığın-30 üzerinde PDD2'nin kavram kayması tespiti*

Yığın 3 ve 5'te en önemli değişken `feature_2` bulunmuşken diğer yığın sayılarında ise `feature_1` değişken en önemli değişken olarak tespit edilmiştir.

feature_1 değişkeninde artış meydana geldiğinde ortalama tahmin değerinde düşüş gözlemlenmektedir. feature_2 değişkeninde artış meydana geldiğinde ise tersi durum söz konusudur. Genel olarak PDP eğrileri tüm yığın sayılarında birbirine yakındır ancak düz bir trend yoktur. Her iki değişken için de zikzaklar mevcuttur. Tüm yığın sayılarında L2 metriği düşük ve birbirine yakın değerler alıyorken, PDI ve L2Der metrikleri daha fazla değişkenlik göstermektedir. Ayrıca PDD2 sadece performans metriği üzerinden karar vermeyen bir yöntem olup, diğer yığınlara göre daha yüksek bir doğruluk olduğunda da kayma tespitinde bulunmuştur (Bkz. Şekil 4.14. İndeks 13, 30).

4.3. NOAA (Weather) Veri Seti

1949-1999 döneminde Nebraska'daki Offutt Hava Üssü'nde sıcaklık, basınç, rüzgar hızı gibi sekiz farklı özellik ölçülmüştür. Amaç, belirli bir günde yağmur yağıp yağmayacağını tahmin etmektir. Veri setinde 18159 gözlem, 8 sürekli bağımsız değişken ve yağmur yağmaması yönünde dengesizlik gösteren 12461 adet 0 ve 5698 adet 1 sınıfına ait gözlem bulunmaktadır (Elwell & Polikar., 2011).

Tablo 4.3. NOAA veri seti için deney sonuçları

Yöntem	Yığın Sayısı							
	3		5		10		15	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,7699	0	0,8170	2	0,7790	0	0,7898	1
HDDM-W	0,7739	2	0,8255	4	0,7883	4	0,7999	10
KSWIN	0,7741	3	0,8241	5	0,7916	10	0,8019	15
PH	0,7699	0	0,8170	2	0,7869	3	0,7898	2
DDM	0,7699	0	0,8241	5	0,7818	1	0,7957	2
EDDM	0,7741	3	0,8241	5	0,7916	10	0,8019	15
PDD	0,7704	1	0,8202	1	0,7839	1	0,7876	1
Test	0,8217		0,7722		0,7723		0,7744	
Eğitim	0,9998		0,9996		0,9996		1	
Eğitim-Test	9684	2422	7263	1816	4842	1211	3631	908


Tablo 4.3 (Devam) *NOAA veri seti için deney sonuçları*

Yöntem	Yığın Sayısı					
	20		25		30	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,7783	4	0,7786	6	0,7780	2
HDDM-W	0,7835	10	0,7826	9	0,7826	9
KSWIN	0,7916	19	0,7912	24	0,7945	29
PH	0,7798	3	0,7719	1	0,7772	3
DDM	0,7914	20	0,7837	6	0,7831	8
EDDM	0,7914	20	0,7931	25	0,7940	30
PDD	0,7676	0	0,7750	1	0,7723	2
Test	0,8338		0,8320		0,8154	
Eğitim	0,9997		0,9996		0,9995	
Eğitim-Test	2904	727	2420	606	2075	519

NOAA veri seti için sonuçlar Tablo 4.3.'de verilmiştir. HDDM-A yöntemi, genellikle düşük kayma sayısı ile yüksek doğruluk oranları sergilemektedir. Örneğin, yığın sayısı 3 ve 10 olduğunda kayma tespit edilmezken, doğruluk oranları sırasıyla 0.7699 ve 0.7790 olarak gözlemlenmiştir. HDDM-W yöntemi ise daha yüksek doğruluk oranlarına sahip olup, kayma tespit etme konusunda daha hassastır; örneğin, yığın sayısı 10 olduğunda doğruluk oranı 0.7883 iken kayma sayısı 4 olarak tespit edilmiştir. KSWIN yöntemi, yığın sayısına bağlı olarak yüksek kayma sayıları tespit etmekte ve bu veri seti özelinde kayma tespitinde oldukça hassas olduğunu göstermektedir. Örneğin, yığın sayısı 30 olduğunda kayma sayısı 29 olarak tespit edilmiştir. PH yöntemi ise genellikle yüksek doğruluk oranlarına sahip olup, düşük kayma sayısı ile stabil performans sergilemektedirler. EDDM yöntemi de benzer şekilde yüksek doğruluk oranlarına sahiptir ancak daha yüksek kayma sayıları tespit etmektedir; özellikle büyük yığın sayılarında bu durum daha belirgindir. PDD yöntemi ise diğer yöntemlere göre biraz daha düşük doğruluk oranlarına sahip olmakla birlikte, tutarlı ve düşük sayıda kayma tespiti ile öne çıkmaktadır. Örneğin, yığın sayısı 5 olduğunda doğruluk oranı 0.8202, kayma sayısı ise 1 olarak tespit edilmiştir. Yığın sayısının artması genellikle doğruluk oranlarını artırmakta, ancak kayma tespit eden yöntemlerde (özellikle KSWIN ve EDDM) kayma değerlerinin de artmasına neden olmaktadır. Sonuç olarak, PDD, HDDM-A ve PH yöntemleri düşük sayıda kayma ve yüksek doğruluk sağladıkları için tercih edilebilirken, KSWIN ve EDDM yöntemleri yüksek sayıda kayma tespit etmeleri nedeniyle daha

dinamik güncellemeler gerektirebilir. PDI yöntemi ise düşük kayma ve makul doğruluk oranları ile stabil bir seçenek olarak değerlendirilebilir.

Test - Doğruluk: 0.82 - PDI: 0.08 - L2Der: 0.01 - L2: 0.17




İndeks: 3 - Doğruluk: 0.75 - PDI: 0.21 - L2Der: 0.03 - L2: 1.12



Şekil 4.15. NOAA veri seti için yığın-3 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.77 - PDI: 0.12 - L2Der: 0.01 - L2: 0.19




İndeks: 2 - Doğruluk: 0.8 - PDI: 0.16 - L2Der: 0.02 - L2: 0.23



Şekil 4.16. NOAA veri seti için yığın-5 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.77 - PDI: 0.06 - L2Der: 0.01 - L2: 0.15




İndeks: 2 - Doğruluk: 0.79 - PDI: 0.08 - L2Der: 0.03 - L2: 0.42




Şekil 4.17. NOAA veri seti için yığın-10 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.77 - PDI: 0.05 - L2Der: 0.04 - L2: 0.12




İndeks: 15 - Doğruluk: 0.74 - PDI: 0.11 - L2Der: 0.07 - L2: 0.16




Şekil 4.18. NOAA veri seti için yığın-15 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.83 - PDI: 0.02 - L2Der: 0.02 - L2: 0.22




İndeks: 1 - Doğruluk: 0.8 - PDI: 0.13 - L2Der: 0.06 - L2: 0.27




Şekil 4.19. NOAA veri seti için yığın-25 üzerinde PDD'nin kavram kayması tespiti


Test - Doğruluk: 0.82 - PDI: 0.11 - L2Der: 0.01 - L2: 0.06



İndeks: 1 - Doğruluk: 0.81 - PDI: 0.19 - L2Der: 0.03 - L2: 0.18



İndeks: 23 - Doğruluk: 0.78 - PDI: 0.2 - L2Der: 0.04 - L2: 0.87



Şekil 4.20. NOAA veri seti için yığın-30 üzerinde PDD'nin kavram kayması tespiti

PDD yöntemi, genel olarak ilk indekslerden itibaren kavram kayması tespit etmiştir.

Yığın sayısına bağlı olarak `attribute2`, `attribute4` değişkenleri en önemli değişken olarak bulunmuştur. Genel olarak `attribute2` değişkeni 25-75 değerleri arasında değişiklik göstermiştir, `attribute2`'deki 25'den sonraki artış yaklaşık 65 civarına kadar eğrilerin birbirinden uzaklaşmasına neden olmuştur. Bu değişiklik genel olarak yanıt değişkeninin ortalama tahmininde düşüşe neden olmuştur. PDD yöntemi, eğitim ve test setlerinde benzer PDP eğrilerine sahip değişkenler için düşük metrikler hesaplandığında genel olarak yeni gelen yığınlarda kavram kayması tespit etmektedir. Örneğin, yığın 30'da (Bkz. Şekil 4.20.) bu durum net bir şekilde görülmektedir. Ters durum ise `attribute4` değişkeninde ortaya çıkmıştır. Eğitim ve test setlerinde PDP eğrileri birbirinden uzak olduğundan daha sonradan kayma tespit etmek daha güç hale gelmiştir (Bkz. Şekil 4.18. ve 4.19.)

4.4. Ozone Veri Seti

Ozon Seviyesi Tespit veri setine dayanmaktadır (Zhang & Fan, 2008). Bu veri seti, 2536 gözlem ve 73 değişken içermektedir. Ayrıca, Houston bölgesindeki çeşitli hava kirleticileri ve meteorolojik bilgileri tanımlayan 72 sürekli bağımsız değişken bulunmaktadır. Bağımlı değişken iki sınıfa sahip olup 2374 adet 0 ve 160 adet 1 bulunmaktadır.

Tablo 4.4. Ozone veri seti için deney sonuçları


Yöntem	Yığın Sayısı							
	3		5		10		15	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,9548	0	0,9607	0	0,9508	0	0,9463	1
HDDM-W	0,9548	0	0,9607	0	0,9508	0	0,9463	1
KSWIN	0,9548	0	0,9599	1	0,9529	1	0,9463	3
PH	0,9548	0	0,9607	0	0,9508	0	0,9457	0
DDM	0,9538	2	0,9607	0	0,9513	2	0,9494	8
EDDM	0,9548	1	0,9599	1	0,9524	2	0,9452	2
PDD	0,9548	1	0,9607	0	0,9502	1	0,9383	1
Test	0,9764		0,9569		0,9941		0,8516	
Eğitim	1,0000		1,0000		1,0000		1,0000	
Eğitim-Test	1351	338	1013	254	675	169	506	127

Tablo 4.4. (Devam) *Ozone veri seti için deney sonuçları*


Yöntem	Yığın Sayısı					
	20		25		30	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,9427	1	0,9391	1	0,9374	0
HDDM-W	0,9427	1	0,9391	1	0,9401	1
KSWIN	0,9383	4	0,9395	6	0,9437	3
PH	0,9422	0	0,9395	0	0,9374	0
DDM	0,9427	2	0,9409	3	0,9437	3
EDDM	0,9441	3	0,9353	3	0,9437	3
PDD	0,9422	0	0,9405	1	0,9445	2
Test	0,9806		1		1	
Eğitim	1		1		1	
Eğitim-Test	404	102	337	85	289	73

Ozone veri seti için sonuçlar Tablo 4.4.'de verilmiştir. Veri seti yüksek oranda dengesiz bir veri setidir, tüm gözlemler 0 olarak tahmin edildiğinde doğruluk oranı 0.9368'dir. Klasik istatistiksel testler hatalar üzerinden kayma tespit etmeye çalıştığı için önceki uygulamalarda kayma sayısının yığın sayısına oranında düşüş gözlemlenmiştir. Özellikle KSWIN ve EDDM yöntemleri önceki uygulamalarda genel olarak yığın sayısına yakın ya da eşit kayma tespit ederken burada bu oran ciddi biçimde düşmüştür. PH testi ise kayma tespit etmemiştir ve model performansı yığın sayısı arttıkça düşmüştür. HDDM-A ve HDDM-W düşük yığın sayılarında kavram kayması tespit edememiştir, yığın sayısı arttığında ise düşük sayıda kavram kayması tespit etmiştir. PDD ise önceki örneklerde olduğu gibi az sayıda kavram kayması tespit etmiştir.

Test - Doğruluk: 0.98 - PDİ: 0.06 - L2Der: 0.01 - L2: 0.25




İndeks: 3 - Doğruluk: 0.94 - PDİ: 0.16 - L2Der: 0.02 - L2: 0.51




Şekil 4.21. Ozon veri seti için yığın-3 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.99 - PDİ: 0.13 - L2Der: 0 - L2: 0.25




İndeks: 1 - Doğruluk: 0.79 - PDİ: 0.35 - L2Der: 0.01 - L2: 0.48




Şekil 4.22. Ozon veri seti için yığın-10 üzerinde PDD'nin kavram kayması tespiti

Test - Doğruluk: 0.85 - PDI: 0.13 - L2Der: 0.04 - L2: 0.12




İndeks: 2 - Doğruluk: 0.95 - PDI: 0.18 - L2Der: 0.08 - L2: 0.18




Şekil 4.23. Ozon veri seti için yığın-15 üzerinde PDD'nin kavram kayması tespiti


Test - Doğruluk: 1 - PDI: 0.22 - L2Der: 0 - L2: 0.73



İndeks: 1 - Doğruluk: 0.93 - PDI: 0.53 - L2Der: 0 - L2: 1.53



Şekil 4.24. Ozon veri seti için yığın-25 üzerinde PDD'nin kavram kayması tespiti



Şekil 4.25. Ozon veri seti için yığın-30 üzerinde PDD'nin kavram kayması tespiti

Ozon veri setinde önceki uygulamalarda olduğundan çok daha fazla sayıda bağımsız değişken bulunmaktadır. PDD yönteminde yığın sayısı değiştikçe en önemli değişken de değişmiştir. Önceki uygulamalardan farklı olarak kayma tespit edildiğinde PDP eğrileri arasında ciddi farklılıklar olduğu gözükmemektedir.

4.5. Elec2 Veri Seti

Bu veri, arz ve talep tarafından etkilenen fiyatlara sahip Avustralya Yeni Güney Galler Elektrik Piyasası'na ait bilgileri içermektedir. Elec2 veri seti 8 bağımsız değişken ve bir yanıt değişkeni içerir. Her bir gözlem 30 dakikalık bir dönemi ifade eder ve sınıf etiketi, son 24 saate kıyasla değişimi (daha yüksek veya daha düşük) ifade eder. Veri seti 45075 adet gözlem içermektedir. İki sınıftan oluşan yanıt değişkeninde 19237 adet UP, 26075 adet DOWN bulunmaktadır.

Literatürde modelleme sırasında 4 bağımsız değişken (*vicprice*, *vicdemand*, *nswprice*, *nswdemand*) modele dahil edilmiştir (Riso & Guerzoni, 2022) bu çalışmada da bu değişkenler ile model kurulmuştur.


Tablo 4.5. *Elec2 veri seti için deney sonuçları*

Yöntem	Yığın Sayısı							
	3		5		10		15	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,6780	3	0,675	5	0,7029	10	0,7187	15
HDDM-W	0,6780	3	0,675	5	0,7029	10	0,7187	15
KSWIN	0,6780	3	0,675	5	0,7029	10	0,7187	15
PH	0,6780	3	0,675	5	0,6992	8	0,7122	9
DDM	0,6780	3	0,675	5	0,7029	10	0,7187	15
EDDM	0,6780	3	0,675	5	0,7029	10	0,7187	15
PDD2	0,7018	0	0,6671	2	0,6947	6	0,723	4
Test	0,6485		0,7381		0,8107		0,8368	
Eğitim	0,8912		0,8824		0,8424		0,8391	
Eğitim-Test	24166	6042	18124	4532	12083	3021	9062	2266

Yöntem	Yığın Sayısı					
	20		25		30	
	Doğruluk	Kayma	Doğruluk	Kayma	Doğruluk	Kayma
HDDM-A	0,7243	20	0,7337	25	0,7374	30
HDDM-W	0,7243	20	0,7337	25	0,7374	30
KSWIN	0,7243	20	0,7337	25	0,7374	30
PH	0,7103	11	0,7219	15	0,7368	16
DDM	0,7250	16	0,7337	25	0,7253	17
EDDM	0,7243	20	0,7337	25	0,7374	30
PDD2	0,7180	4	0,7278	6	0,7413	2
Test	0,8142		0,7612		0,804	
Eğitim	0,8367		0,836		0,8418	
Eğitim-Test	7249	1813	6041	1511	5178	1295

Elec2 veri seti için sonuçlar Tablo 4.5.'de verilmiştir. Deneyde 30 yığın sayısı hariç diğer yığın sayılarında istatistiksel testler yüksek sayıda kayma tespit etmiştir. PH testi diğer testlere göre yığın sayısı 10'dan fazla olduğu durumlarda giderek azalan oranda kayma tespit etmiştir. PDD2 ise çok daha az sayıda kayma tespit etmesine rağmen istatistiksel testler ile ulaşılan model performansına yakın bir performans göstermiştir. Özellikle yığın sayısı 15 iken PH testi 9, diğer testler 15, PDD2 ise 4 kayma tespit etmiştir ve en yüksek model performansına PDD2 ile ulaşılmıştır. Yine benzer şekilde yığın sayısı

30 olduğu durumda PDD2 ile sadece 2 tane kavram kayması tespit edilmiş olmasına rağmen en yüksek model performansına ulaşılmıştır. Aşağıda PDD2 yöntemi ile kayma tespit edilen durumlardaki PDP eğrileri bulunmaktadır.



Şekil 4.26. Elec2 veri seti için yığın-5 üzerinde PDD2'nin kavram kayması tespiti

Test - Doğruluk: 0.81 - PDI: 0.16 - L2Der: 1.84 - L2: 0.01




İndeks: 1 - Doğruluk: 0.77 - PDI: 0.32 - L2Der: 1.26 - L2: 0.02



İndeks: 2 - Doğruluk: 0.72 - PDI: 0.32 - L2Der: 1.72 - L2: 0.05



İndeks: 3 - Doğruluk: 0.74 - PDI: 0.25 - L2Der: 1.85 - L2: 0.07




İndeks: 4 - Doğruluk: 0.66 - PDI: 0.69 - L2Der: 1.88 - L2: 0.05



İndeks: 5 - Doğruluk: 0.65 - PDI: 0.12 - L2Der: 3.28 - L2: 0.07




İndeks: 8 - Doğruluk: 0.64 - PDI: 0.35 - L2Der: 1.87 - L2: 0.08



Şekil 4.27. Elec2 veri seti için yığın-10 üzerinde PDD2'nin kavram kayması tespiti


Test - Doğruluk: 0.84 - PDI: 0.31 - L2Der: 1.64 - L2: 0.02




İndeks: 1 - Doğruluk: 0.82 - PDI: 0.49 - L2Der: 1.83 - L2: 0.01




İndeks: 4 - Doğruluk: 0.7 - PDI: 0.47 - L2Der: 3.47 - L2: 0.03



İndeks: 5 - Doğruluk: 0.79 - PDI: 0.54 - L2Der: 3.72 - L2: 0.07




İndeks: 9 - Doğruluk: 0.66 - PDI: 0.82 - L2Der: 5.02 - L2: 0.08



Şekil 4.28. Elec2 veri seti için yığın-15 üzerinde PDD2'nin kavram kayması tespiti

Test - Doğruluk: 0.81 - PDI: 0.34 - L2Der: 8.31 - L2: 0.03




İndeks: 2 - Doğruluk: 0.67 - PDI: 0.52 - L2Der: 0.97 - L2: 0.05




İndeks: 16 - Doğruluk: 0.77 - PDI: 0.03 - L2Der: 1.05 - L2: 0.06



İndeks: 17 - Doğruluk: 0.69 - PDI: 0.32 - L2Der: 4.74 - L2: 0.08



İndeks: 20 - Doğruluk: 0.75 - PDI: 0.45 - L2Der: 4.86 - L2: 0.03



Şekil 4.29. Elec2 veri seti için yığın-20 üzerinde PDD2'nin kavram kayması tespiti


Test - Doğruluk: 0.76 - PDI: 0.45 - L2Der: 3.04 - L2: 0.02




İndeks: 1 - Doğruluk: 0.79 - PDI: 0.46 - L2Der: 3.41 - L2: 0.01



İndeks: 4 - Doğruluk: 0.83 - PDI: 0.49 - L2Der: 2.36 - L2: 0.02



İndeks: 19 - Doğruluk: 0.8 - PDI: 0.49 - L2Der: 0.17 - L2: 0.04




İndeks: 20 - Doğruluk: 0.71 - PDI: 0.13 - L2Der: 3.15 - L2: 0.06




İndeks: 21 - Doğruluk: 0.68 - PDI: 0.41 - L2Der: 6.77 - L2: 0.06



İndeks: 22 - Doğruluk: 0.8 - PDI: 0.73 - L2Der: 4.36 - L2: 0.07



Şekil 4.30. Elec2 veri seti için yığın-25 üzerinde PDD2'nin kavram kayması tespiti



Şekil 4.31. Elec2 veri seti için yığın-30 üzerinde PDD2'nin kavram kayması tespiti

nswprice değişkeni için oluşturulan PDP eğrilerinde genel olarak 0.15 civarından sonra stabil bir durum gözlemlenmektedir. Gözlemler genel olarak 0 ve 0.1 arasında bulunup bu aralıkta değişkenlik gösterdiği ve aykırı değerler bulunmasından dolayı eğrileri incelemek diğer veri setlerine göre daha zordur. Aynı zamanda izlenen değişken yığınlara göre farklı dağılımlar göstermektedir. Bu gibi durumlarda klasik istatistiksel yöntemlerle verinin dağılımının incelenmesinde modeldeki ilişkinin korunuyor olup olmadığını incelemek daha önemli olabilir. Bu gibi durumlarda klasik yöntemlere göre PDD yöntemi avantaj sağlar. Ancak kayma tespitinde başarılı olsa da görselleştirme konusunda geliştirilebilir.

4.6. Friedman Veri Seti (Regresyon)

Veri seti, sentetik bir veri seti olup, River Python paketi kullanılarak oluşturulmuştur. Toplamda 20.000 gözlem içermektedir. Synth.FriedmanDrift fonksiyonu kullanılarak `drift_type = 'gra', position = (17500,`

19000) ve seed=42 olarak belirlenmiştir. 'gra', yani global recurring abrupt drift, tüm örnek alanı boyunca kavram kaymasının ortaya çıktığını ifade eder (Ikonovska vd., 2011). Bu veri setinde, kavram kaymasının iki noktada meydana geldiği ve ikinci kayma noktasında eski kavramın yeniden ortaya çıktığı gözlemlenmektedir. Veri setinde 10 tane bağımsız sürekli değişken ve sürekli yanıt değişkeni bulunmaktadır. Diğer deneylerde olduğu gibi rassal orman modeli kullanılarak regresyon modeli oluşturulmuştur. İstatistiksel testlerde yanıt değişkenindeki değişiklik RMSE (Root Mean Square Error) metriği üzerinden takip edilmiştir. Sürekli değerlerin takibinde her test uygun olmadığı için sadece PH ve KSWIN testleri kullanılmıştır.

Önceki çalışmalarda olduğu gibi PDD ve PDD2 kayma tespitinde kullanılmıştır. PDP eğrileri şekil olarak birbirlerine çok benzedikleri için PDI metriği genel olarak 0 değerini almıştır. Önceki çalışmalardan farklı olarak burada, L2 veya L2Der metrikleri önceki durumdan %10 artış gösterdiğinde kavram kayması olarak değerlendirilmiş ve PDD3 şeklinde deney sonuçları tabloya eklenmiştir.


Tablo 4.6. Friedman veri seti için deney sonuçları

Yöntem	Yığın Sayısı							
	3		5		10		15	
	RMSE	Kayma	RMSE	Kayma	RMSE	Kayma	RMSE	Kayma
KSWIN	2,637	0	2,049	0	2,082	0	1,964	0
PH	2,637	0	2,049	0	2,082	0	1,964	0
PDD	2,637	0	2,049	0	2,082	0	1,927	1
PDD2	2,606	2	1,988	2	2,039	1	1,927	1
PDD3	2,602	3	1,886	4	2,016	5	1,841	8
Test	1,609		1,583		1,639		1,778	
Eğitim	0,694		0,704		0,727		0,759	
Eğitim-Test	10666	2667	8000	2000	5332	1334	4000	1000

Yöntem	Yığın Sayısı					
	20		25		30	
	RMSE	Kayma	RMSE	Kayma	RMSE	Kayma
KSWIN	1,998	0	2,109	0	2,098	0
PH	1,998	0	2,109	0	2,098	0
PDD	1,960	1	2,042	1	2,056	2
PDD2	1,942	2	2,016	2	2,043	2
PDD3	1,885	11	1,944	10	1,943	14
Test	1,775		1,705		1,745	
Eğitim	0,765		0,798		0,810	
Eğitim-Test	3200	800	2666	667	2285	572


Friedman veri seti için sonuçlar Tablo 4.6.'da verilmiştir. RMSE metriği incelendiğinde KSWIN ve PH testleri herhangi bir kavram kayması tespit etmemiştir. PDD ise yığın sayısı 15 ve sonrasında düşük seviyede kavram kayması tespit etmiştir. PDD2 ise tüm yığın sayılarında kavram kayması tespit etmiştir. Ancak genel olarak PDD'ye yakın sonuçlar elde edilmiştir. PDD3 ise 3 ve 5 yığın sayısına sahip deneylerin hepsinde kayma tespit ederken, 10 ve sonrasındaki yığın sayılarında ise genelde yığın sayısının yarısına yakın kavram kayması tespit etmiştir. Model performansları açısından PDD3 özellikle yüksek sayıda yığın sayısı olduğunda her yığında modeli güncellememiştir ancak model performansını diğer testlere göre arttırmıştır.

PDD, PDD2 ve PDD3 yöntemleri benzer PDP eğrileri üretmiştir. Aşağıda sadece PDD2 için eğriler eklenmiştir. (PDD ve PDD3 grafikleri için https://github.com/ugurda/YL-TEZ/tree/main/friedman_sonuc)




Şekil 4.32. Friedman veri seti için yığın-3 üzerinde PDD2'nin kavram kayması tespiti


Test - RMSE: 1.58 - PDI: 0 - L2Der: 0.49 - L2: 0.08



İndeks: 2 - RMSE: 1.62 - PDI: 0 - L2Der: 0.68 - L2: 0.25




İndeks: 3 - RMSE: 1.51 - PDI: 0 - L2Der: 0.77 - L2: 0.34




Şekil 4.33. Friedman veri seti için yığın-5 üzerinde PDD2'nin kavram kayması tespiti

Test - RMSE: 1.64 - PDI: 0 - L2Der: 0.35 - L2: 0.13




İndeks: 1 - RMSE: 1.69 - PDI: 0 - L2Der: 0.87 - L2: 0.74




Şekil 4.34. Friedman veri seti için yığın-10 üzerinde PDD2'nin kavram kayması tespiti

Test - RMSE: 1.78 - PDI: 0 - L2Der: 1.16 - L2: 0.11




İndeks: 5 - RMSE: 1.73 - PDI: 0 - L2Der: 1.32 - L2: 0.81




Şekil 4.35. Friedman veri seti için yığın-15 üzerinde PDD2'nin kavram kayması tespiti

Test - RMSE: 1.78 - PDI: 0 - L2Der: 0.59 - L2: 0.05



İndeks: 1 - RMSE: 1.82 - PDI: 0 - L2Der: 0.68 - L2: 0.26




İndeks: 13 - RMSE: 1.67 - PDI: 0 - L2Der: 1.31 - L2: 0.52




Şekil 4.36. Friedman veri seti için yığın—20 üzerinde PDD2'nin kavram kayması tespiti


Test - RMSE: 1.71 - PDI: 0 - L2Der: 0.41 - L2: 0.1



İndeks: 1 - RMSE: 1.85 - PDI: 0.01 - L2Der: 1.24 - L2: 0.44




İndeks: 9 - RMSE: 1.69 - PDI: 0 - L2Der: 1.67 - L2: 0.51




Şekil 4.37. Friedman veri seti için yığın-25 üzerinde PDD2'nin kavram kayması tespiti


Test - RMSE: 1.75 - PDI: 0 - L2Der: 0.55 - L2: 0.03



İndeks: 1 - RMSE: 1.78 - PDI: 0 - L2Der: 1.68 - L2: 0.23



İndeks: 9 - RMSE: 1.83 - PDI: 0 - L2Der: 1.95 - L2: 0.24



Şekil 4.38. Friedman veri seti için yığın-30 üzerinde PDD2'nin kavram kayması tespiti

PDP eğrileri genel olarak şekil olarak birbirine benzerlik göstermektedir. Eğitim ve test setlerinde neredeyse birebir çakışan eğriler olduğu görülmektedir. Ancak farklı yığınlarda L2 ve L2Der metriklerinde değişiklikler meydana gelmiştir. Bu durumlar PDD2 ile kavram kaymasına işaret etmektedir.

5. SONUÇ

Bu tezde kavram kaymasının tespitinde kullanılan istatistiksel testler Page Hinkley (PH), Kolmogorov-Smirnov Pencereleme (KSWIN – *Kolmogorov Smirnov Windowing*), Kavram Kayması Tespit Yöntemi (DDM - *Drift Detection Method*), Erken Kavram Kayması Tespit Yöntemi (EDDM – *Early Drift Detection Method*), Hoeffding Eşitsizliğine Dayalı Kavram Kayması Yöntemi (HDDM-A - HDDM-W - *Hoeffding's Drift Detection Method – Average/Weighted*) ve Açıklanabilir Yapay Zekâ (AYZ) yöntemlerinden birisi olan ve bağımsız değişkenin yanıt değişkeninin ortalama tahminine katkısını inceleyen Kısmi Bağımlılık Profilleri (PDP) eğrilerinin arasındaki değişim ile kavram kaymasının tespit edilmesi amacıyla bu tez çalışmasında geliştirilen Profil Kayması Tespiti (PDD – *Profile Drift Detection*) kıyaslanmıştır. Uygulamalarda literatürde kavram kayması üzerine yapılan çalışmalarda kullanılan 3 gerçek hayat, 3 sentetik veri seti kullanılmıştır.

PDD, iki PDP eğrisi arasında PDI, L2 (öklidyen uzaklık), L2Der (türevleri arasındaki öklidyen uzaklık) metrikleri inceler. Varsayılan olarak bu üç metrik eğitim ve test setlerinden elde edilen PDP'ler üzerinden eşik değer olarak atanır ve yeni gelen yığınlarda test verisindeki eşik değer kıyaslanır, eğer yeni gelen yığında bu üç metrikte de artış meydana geldiyse, yöntem kavram kaymasına işaret eder ve eşik değerler güncellenir. Bu çalışmada incelenecek değişken seçimi için eğitim setinde rassal orman ile oluşturulan modeldeki en önemli değişken seçilmiştir. İstatistiksel testlerde de, testlerin parametrelerinin ayarlanması gerekmektedir. Farklı tipte veriler ve kayma türleri için bu testler daha fazla ya da az hassas hale getirilebilir. Benzer durum PDD için de geçerlidir. Bu çalışmada PDD'de varsayılan olarak üç koşulun sağlanması kavram kaymasına işaret ederken, deneylerde varsayılanın haricinde PDD2 üç metriktan en az ikisinde eşik değer aşılması, PDD3 eşik değerlerin belli bir oranda aşılması gibi farklı koşullar da ele alınmıştır. Çalışmada, istatistiksel testler ve PDD farklı yığın sayılarında kayma tespiti sayısı ve model performansı bakımından karşılaştırılmıştır.

Bu tezin asıl amaçlarından biri kavram kaymasını tespit ederken aynı zamanda kaymanın ortaya çıktığı durumlarda model-değişken arasındaki ilişkiyi daha iyi anlamaktır. Klasik istatistiksel yöntemler genel olarak yanıt değişkeninin doğru tahmin edilip edilemeyeceği üzerinden kavram kaymasının tespitinde kullanılırken, PDD hem kavram kayması tespitinde hem de değişimi daha iyi anlamak için kullanılabilir. Ayrıca

PDP, yanıt değişkenin doğru tahmin edilip edilmediğini baz almadığı için yüksek doğruluk oranlarında da kavram kayması tespit etmiştir. Bu durum verideki ilişkiler değiştiğinde ancak halâ model değerlendirme (*accuracy*, F1, vd.) metriğinde herhangi bir değişimin gözlemlenmediği durumlarda bu değişimin tespit edilerek modelin güncellenmesine olanak tanır. Bu çalışmada, yeni gelen yığınlardaki yanıt değişkenindeki değer üzerinden PDP'ler hesaplanmıştır ancak KSWIN, ADWIN ya da PH gibi gerçek değer gelmesinin beklenmesine gerek yoktur, PDP'ler tahmin edilen yanıt değişkeni ile de hesaplanabilir.

SEA sentetik veri seti üzerindeki deneylerde, PDD yöntemi diğer istatistik testlere göre model performansı bakımından yakın sonuçlar vermiştir. PDD, yığın sayısı arttıkça diğer testlere oranla daha az kavram kayması tespit etmiştir. Bu nedenle model yeni gelen yığınlarda daha az güncellenmiştir. Bu da model eğitime maliyetini ciddi oranda düşürebilir. PDD, PH ve DDM testleri kavram kayması tespitinde ve model performansında birbirine yakın sonuçlar vermiştir.

Hyperplane sentetik veri seti üzerinde yapılan deneylerde, PDD yöntemi düşük yığın sayılarında diğer istatistiksel testlere benzer yer yer daha iyi sonuçlar verse de yığın sayısı 20, 25 ve 30'da diğer istatistiksel testlere göre kavram kayması tespiti ve model performansı bakımından düşük sonuçlar vermiştir. PDD2 ise HDDM-W'ye benzer sayıda kavram kayması tespit etmiştir.

NOAA gerçek hayat veri seti üzerinde yapılan deneylerde ise PDD yöntemi ile genel olarak PH testine benzer sonuçlar elde edilmiştir. Bu iki test diğer testlere göre daha az sayıda kavram kayması tespit etmiştir. KSWIN ve EDDM testleri her yığında kavram kayması tespit etmiştir ancak modelin çok daha az güncellendiği diğer istatistiksel yöntemlerden yüksek model performansına ulaşılmış olsa da bu fark maksimum 0,02 seviyelerinde kalmıştır.

Ozone veri setinde yüksek seviyede sınıf dengesizliği bulunmaktadır. Bu veri seti üzerinde yapılan deneylerde istatistiksel testler ile model tahmin değerinin, gerçek değerden farklı olup olmaması gözlemlendiğinden genel olarak istatistiksel testler diğer veri setlerinde olduğundan daha az sayıda kavram kayması tespit etmiştir. Her ne kadar dengesiz veri setlerinde doğruluk metriği model performansının değerlendirilmesi

açısından doğru seçim olmasa da PDD yöntemi diğer yöntemlerle benzer model performansına sahip olduğu gözlemlenmektedir.

Elec2 veri seti kavram kayması tespitinde literatürde en sık kullanılan veri setlerinden bir tanesidir. Bu çalışmada yapılan deneylerde, PH testi haricinde diğer klasik istatistiksel testler genel olarak her yığın sayısı için her yığında kavram kayması tespit etmiş ve modeli güncellemiştir. PDD2 ise çok daha az sayıda kavram kayması tespit etmiştir ancak model performansı açısından diğer testlere çok yakın ya da daha yüksek sonuçlar vermiştir.

Sentetik bir veri seti olan Friedman veri seti ise diğer veri setlerinden farklı olarak sürekli yanıt değişkeni içermektedir. Her istatistiksel test sürekli değişkenler için uygun olmadığından istatistiksel testlerden KSWIN ve PH testleri kullanılmıştır. RMSE (*Root Mean Square Error*) metriği üzerinden kayma tespit edilmeye çalışıldığında ise bu iki test herhangi bir kayma tespit etmemişken, PDD'ler ile kavram kayması tespitinde ve model performansında daha başarılı olmuşlardır.

PDD bazı dezavantajlara da sahiptir, örneğin az sayıda seviyeye sahip kategorik değişkenlerde türev hesabı zorlaşabilir ve bu PDD'nin metrikleri hesaplayamamasına neden olabilir. PDD varsayılan olarak modeldeki en önemli değişkeni baz alarak işlemleri bunun üzerinden sürdürür ancak bağımsız değişken sayısı arttığında ya da bağımsız değişkenlerin yanıt değişkenine katkısı (önemliliği) arttığında sadece en önemli değişken üzerinden kavram kayması tespiti yapıldığı için, diğer değişkenlerden kaynaklı kayma tespit edilemeyebilir, bu gibi durumlarda diğer bağımsız değişkenler üzerinden de kavram kayması tespit edilmesi gerekir ancak bu durum PDD hesaplama maliyetini artırır. Çok sayıda bağımsız değişkene sahip olunan durumlarda en önemli değişkenin her yığında güncellenmesi de gerekebilir. PDD, daha seyrek (*sparse*) vektörler üzerinde küçük değişikliklerden daha fazla etkilenebilir bunun nedeni PDD için hesaplanan 3 metriğin seçilen tüm gözlem noktalarında hesaplanan değerlerin ortalaması olmasıdır. Örneğin, PDI metriği türev yönlerinin aynı olup olmadığını ölçen bir metriktir. 100 gözlem içerisinde 5 noktada farklı türev yönlerine sahip vektörler için PDI 0.05 olarak hesaplanır, 5 gözlem içerisinde 1 noktada farklı türev yönüne sahip vektörler için PDI 0.20'ye çıkar. Bu çalışmada sadece iki seviyeli ve sürekli değerlere sahip yanıt değişkenleri kullanılmıştır, ikiden fazla seviyeye sahip yanıt değişkeni olduğunda PDD yanıt değişkeninin belli bir seviyesi için uyarlanabilir ancak uyarlanması ve takibi maliyetli

olabilir. PDD, PDP'yi baz alan bir yöntem olduğundan, bağımsız değişkenler arasındaki ilişkiyi göz ardı eder. Yüksek derecede ilişki olduğu durumlarda hatalı sonuçlar verebilir. Bu çalışmada PDP hesaplamaları R programlama dilinde yazılmış olan DALEX paketi ile oluşturulmuştur ve hesaplama maliyeti yüksektir. Bu yöntemin uygulamalarda kullanılabilmesi için PDP hesaplamasının daha efektif yapılması gerekmektedir. Hubert vd., (2024) gözlem sayısı çok olduğunda veri dağılımının sıkıştırılması (indirgenmesi) ve sonrasında açıklanabilir yöntemlerin daha efektif uygulanmasına yönelik bir yöntem geliştirmiştir. Bu PDD yöntemine entegre edilerek hesaplama maliyeti düşürülebilir. Ancak model eğitme maliyetinin yüksek olduğu durumlarda şu anki haliyle kullanılabilir. Ayrıca model eğitme maliyetinin, PDP oluşturma maliyetinden düşük olduğu durumlarda da modelde kavram kayması tespit edildiğinde yanıt değişkeni ile bağımsız değişkenin arasındaki ilişkinin nasıl değiştiğini izlemek için kullanılabilir. Güncellenen makine öğrenmesi modelleri belirli model tahminlerini öngörülemez şekilde değiştirilebilir (Daniels vd., 2024). PDD, diğer istatistiksel yöntemlere göre bu tip sorunlarda model ve veri arasındaki ilişkiye dair daha detaylı bilgiler sunabilir. Kullanıcılar verilerinin silinmesini isteyebilir ve bu verilerle eğitilmiş herhangi bir modelden bu ilişkilerin çıkartılması zor bir problemdir, Bourtole vd. (2021) bu sorunu çözmek için verileri bölme ve sıralama üzerinden bir yöntem geliştirmiştir. PDD, literatürde bu gibi problemlere katkıda bulunabilir.

Sonuç olarak PDD, klasik kavram kayması tespit yöntemlerine göre avantaj ve dezavantajlara sahiptir. Yapılan deneylerde kavram kayması tespitinde diğer testlere göre genelde daha az sayıda, tutarlı ve benzer doğruluk oranlarına sahiptir. Ayrıca modeldeki bağımsız değişken ve yanıt değişkeni arasındaki ilişkinin daha detaylı incelenebilmesine olanak tanır.

KAYNAKÇA

- Alaiz-Rodríguez, R., & Japkowicz, N. (2008). Assessing the impact of changing environments on classifier performance. In *Advances in Artificial Intelligence: 21st Conference of the Canadian Society for Computational Studies of Intelligence*, Canadian AI 2008 Windsor, Canada, May 28-30, 2008 Proceedings 21 (pp. 13-24). Springer Berlin Heidelberg.
- Albert Bifet and Ricard Gavalda. "Learning from time-changing data with adaptive windowing." In *Proceedings of the 2007 SIAM international conference on data mining*, pp. 443-448. Society for Industrial and Applied Mathematics, 2007.
- Alla, S., Adari, S. K., Alla, S., & Adari, S. K. (2021). What is mlops?. *Beginning MLOps with MLFlow: Deploy Models in AWS SageMaker, Google Cloud, and Microsoft Azure*, 79-124.
- Baena-Garcia, M., del Campo-Ávila, J., Fidalgo, R., Bifet, A., Gavalda, R., & Morales-Bueno, R. (2006) Early drift detection method. In *Fourth international workshop on knowledge discovery from data streams* (Vol. 6, pp. 77-86).
- Baniecki, H., Casalicchio, G., Bischl, B., & Biecek, P. (2024). Efficient and Accurate Explanation Estimation with Distribution Compression. *arXiv preprint arXiv:2406.18334*.
- Biecek, P., Burzykowski, T. 2021. "Explanatory model analysis", Chapman and Hall / CRC Press, ISBN:9780367135591.
- Biecek, P. (2018). DALEX: Explainers for complex predictive models in R. *Journal of Machine Learning Research*, 19(84), 1-5.
- Biecek, P. Driftr, "Web Sitesi", https://cran-archive.r-project.org/web/checks/2020/2020-06-15_check_results_driftR.html , Son erişim tarihi: 31 Mart 2024.
- Bourtole, L., Chandrasekaran, V., Choquette-Choo, C. A., Jia, H., Travers, A., Zhang, B., ... & Papernot, N. (2021, May). Machine unlearning. In *2021 IEEE Symposium on Security and Privacy (SP)* (pp. 141-159). IEEE.
- Celik, B., Singh, P., & Vanschoren, J. (2023). Online automl: An adaptive automl framework for online learning. *Machine Learning*, 112(6), 1897-1921.
- Cieslak, D. A., & Chawla, N. V. (2009). A framework for monitoring classifiers' performance: when and why failure occurs?. *Knowledge and Information Systems*, 18(1), 83-108.
- Raab, C., Heusinger, M., & Schleif, F. M. (2020). Reactive soft prototype computing for concept drift streams. *Neurocomputing*, 416, 340-351.
- Dar, U., Cavus, M. (2023). A novel concept drift detection method based on the partial dependence profile disparity index. Paper presented at the 7th International Researchers, Statisticians, and Young Statisticians Congress, Istanbul, Türkiye.
- Dar, U., Cavus, M. (2024). Explainable Detection of Data Drift Using Partial Dependence Disparity Index in Real Datasets. Oral Presentation at V. International Applied Statistics Congress, Istanbul, Türkiye.

- Dar U. (2024). *datadriftR: Concept Drift Detection Methods for Stream Data*. R package version 0.0.1, <https://CRAN.R-project.org/package=datadriftR>.
- Demšar, J., & Bosnić, Z. (2018). Detecting concept drift in data streams using model explanation. *Expert Systems with Applications*, 92, 546-559.
- Denis M., Adriana U., Delphine C. (2021). *doremi: Dynamics of Return to Equilibrium During Multiple Inputs*. R package version 1.0.0, <https://CRAN.R-project.org/package=doremi>.
- Duckworth, C., Chmiel, F. P., Burns, D. K., Zlatev, Z. D., White, N. M., Daniels, T. W., ... & Boniface, M. J. (2021). Using explainable machine learning to characterise data drift and detect emergent health risks for emergency department admissions during COVID-19. *Scientific reports*, 11(1), 23017.
- Evidently AI. (2020), Collaborative AI quality platform for ML, LLM, and Gen AI. Evaluate, test, and monitor any AI-powered product. Built on open-source. <https://www.evidentlyai.com/> adresinden alındı.
- Elwell, R., & Polikar, R. (2011). Incremental learning of concept drift in nonstationary environments. *IEEE transactions on neural networks*, 22(10), 1517-1531.
- Febrero-Bande, M., & De La Fuente, M. O. (2012). Statistical computing in functional data analysis: The R package *fda.usc*. *Journal of statistical Software*, 51, 1-28.
- Frias-Blanco, I., del Campo-Ávila, J., Ramos-Jimenez, G., Morales-Bueno, R., Ortiz-Diaz, A., & Caballero-Mota, Y. (2014). Online and non-parametric drift detection methods based on Hoeffding's bounds. *IEEE Transactions on Knowledge and Data Engineering*, 27(3), 810-823.
- Friedrich, B., Sawabe, T., & Hein, A. (2023). Unsupervised statistical concept drift detection for behaviour abnormality detection. *Applied Intelligence*, 53(3), 2527-2537.
- Fumagalli, F., Muschalik, M., Hüllermeier, E., & Hammer, B. (2023). Incremental permutation feature importance (iPFI): towards online explanations on data streams. *Machine Learning*, 112(12), 4863-4903.
- Gama, J., Medas, P., Castillo, G., & Rodrigues, P. (2004). Learning with drift detection. In *Advances in Artificial Intelligence—SBIA 2004: 17th Brazilian Symposium on Artificial Intelligence*, Sao Luis, Maranhao, Brazil, September 29-October 1, 2004. *Proceedings 17* (pp. 286-295). Springer Berlin Heidelberg.
- GDPR, G. D. P. R. (2016). General data protection regulation. Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC.
- Hulten, G., Spencer, L., & Domingos, P. (2001). Mining time-changing data streams. In *Proceedings of the seventh ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 97-106).
- Ikonovska, E., Gama, J., & Džeroski, S. (2011). Learning model trees from evolving data streams. *Data mining and knowledge discovery*, 23, 128-168.

- Inglis, A., Parnell, A., & Hurley, C. B. (2022). Visualizing variable importance and variable interaction effects in machine learning models. *Journal of Computational and Graphical Statistics*, 31(3), 766-778.
- Kobylińska, K., Krzyżiński, M., Machowicz, R., Adamek, M., & Biecek, P. (2023). Exploration of Rashomon Set Assists Explanations for Medical Data. *arXiv preprint arXiv:2308.11446*.
- Masciopinto, F. (2018). Comparison of concept drift detectors in a health-care facility dataset to detect behavioral drifts.
- Mattos, J. G., Silva, T., Lopes, H., & Bordignon, A. L. (2021). Interpretable Concept Drift. In *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 25th Iberoamerican Congress, CIARP 2021, Porto, Portugal, May 10–13, 2021, Revised Selected Papers 25* (pp. 271-280). Springer International Publishing.
- Montiel, J., Halford, M., Mastelini, S. M., Bolmier, G., Sourty, R., Vaysse, R., ... & Bifet, A. (2021). River: machine learning for streaming data in python. *Journal of Machine Learning Research*, 22(110), 1-8.
- Moreno-Torres, J. G., Raeder, T., Alaiz-Rodríguez, R., Chawla, N. V., & Herrera, F. (2012). A unifying view on dataset shift in classification. *Pattern recognition*, 45(1), 521-530.
- Mougan, C., & Nielsen, D. S. (2023). Monitoring model deterioration with explainable uncertainty estimation via non-parametric bootstrap. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 37, No. 12, pp. 15037-15045).
- Moosbauer, J., Herbringer, J., Casalicchio, G., Lindauer, M., & Bischl, B. (2021). Explaining hyperparameter optimization via partial dependence plots. *Advances in Neural Information Processing Systems*, 34, 2280-2291.
- Muschalik, M., Fumagalli, F., Hammer, B., & Hüllermeier, E. (2022). Agnostic explanation of model change based on feature importance. *KI-Künstliche Intelligenz*, 36(3), 211-224.
- Muschalik, M., Fumagalli, F., Jagtani, R., Hammer, B., & Hüllermeier, E. (2023). iPDP: On Partial Dependence Plots in Dynamic Modeling Scenarios. In *World Conference on Explainable Artificial Intelligence* (pp. 177-194). Cham: Springer Nature Switzerland.
- Page, E. S. (1957). On problems in which a change in a parameter occurs at an unknown point. *Biometrika*, 44(1/2), 248-252.
- Rahmani, K., Thapa, R., Tsou, P., Chetty, S. C., Barnes, G., Lam, C., & Tso, C. F. (2023). Assessing the effects of data drift on the performance of machine learning models used in clinical sepsis prediction. *International Journal of Medical Informatics*, 173, 104930.
- Riso, L., & Guerzoni, M. (2022). Concept drift estimation with graphical models. *Information Sciences*, 606, 786-804.

- Sebastião, R., & Fernandes, J. M. (2017). Supporting the page-hinkley test with empirical mode decomposition for change detection. In International Symposium on Methodologies for Intelligent Systems (pp. 492-498). Cham: Springer International Publishing.
- Silge J. (2023). *vetiver: Version, Share, Deploy, and Monitor Models*. R Package version 0.2.5, <https://CRAN.R-project.org/package=vetiver>.
- Štrumbelj, E., Kononenko, I., & Šikonja, M. R. (2009). Explaining instance classifications with interactions of subsets of feature values. *Data & Knowledge Engineering*, 68(10), 886-904.
- Street, W. N., & Kim, Y. (2001). A streaming ensemble algorithm (SEA) for large-scale classification. In *Proceedings of the seventh ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 377-382).
- Watson-Daniels, J., Calmon, F. D. P., D'Amour, A., Long, C., Parkes, D. C., & Ustun, B. (2024). Predictive churn with the set of good models. *arXiv preprint arXiv:2402.07745*.
- Webb, G. I., Hyde, R., Cao, H., Nguyen, H. L., & Petitjean, F. (2016). Characterizing concept drift. *Data Mining and Knowledge Discovery*, 30(4), 964-994.
- Zhang, K., & Fan, W. (2008). Forecasting skewed biased stochastic ozone days: analyses, solutions and beyond. *Knowledge and Information Systems*, 14, 299-326.

EKLER

EK-1. datadriftR Paketi

CRAN: <https://cran.r-project.org/web/packages/datadriftR/index.html>

GitHub: <https://github.com/ugurdar/datadriftR>



ÖZGEÇMİŞ

ORCID NO: 0009-0005-8076-2199

Ad Soyad : Uğur DAR

Yabancı Dil : İngilizce

Doğum Yeri ve Yılı : -

E-Posta : -

Eğitim ve Mesleki Geçmişi:

- 2016-2021, Eskişehir Teknik Üniversitesi, Fen Fakültesi, İstatistik Bölümü
- 2019-2024, Eskişehir Teknik Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü
- 2022-Hâlen, Veri Bilimci, Visbanking, Ürün Geliştirme

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

- Dar, U., Cavus, M. (2023). A novel concept drift detection method based on the partial dependence profile disparity index. Paper presented at the 7th International Researchers, Statisticians, and Young Statisticians Congress, Istanbul, Türkiye.
- Dar, U., Cavus, M. (2024). Explainable Detection of Data Drift Using Partial Dependence Disparity Index in Real Datasets. Oral Presentation at V. International Applied Statistics Congress, Istanbul, Türkiye.